

UNIVERSIDADE FEDERAL DO PARANÁ

ELIETE NASCIMENTO PEREIRA

PROPOSTA DE MODELO HÍBRIDO COMPOSTA POR WAVELET, ARIMA E
REDES NEURAS ARTIFICIAIS DE FUNÇÕES DE BASES RADIAIS PARA
PREVISÃO DE SÉRIES TEMPORAIS: UMA APLICAÇÃO EM UM INSTRUMENTO
DA BARRAGEM DE ITAIPU

CURITIBA

2016

ELIETE NASCIMENTO PEREIRA

PROPOSTA DE MODELO HÍBRIDO COMPOSTA POR WAVELET, ARIMA E
REDES NEURAIS ARTIFICIAIS DE FUNÇÕES DE BASES RADIAIS PARA
PREVISÃO DE SÉRIES TEMPORAIS: UMA APLICAÇÃO EM UM INSTRUMENTO
DA BARRAGEM DE ITAIPU

Tese apresentada ao Programa de Pós-Graduação Métodos Numéricos em Engenharia, na Área de Concentração de Programação Matemática dos Setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná, como requisito parcial à obtenção do grau de Doutor.

Orientador: Prof. Dr. Cassius Tadeu Scarpin
Coorientador: Prof. Dr. Luiz Albino Teixeira Júnior

CURITIBA

2016

P436p

Pereira, Eliete Nascimento

Proposta de modelo híbrido composta por wavelet, arima e redes neurais artificiais de funções de bases radiais para previsão de séries temporais : uma aplicação em um instrumento da barragem de Itaipu/ Eliete Nascimento Pereira. – Curitiba, 2016.

128 f. : il. color. ; 30 cm.

Tese - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-graduação em Métodos Numéricos em Engenharia, 2016.

Orientador: Cassius Tadeu Scarpin – Co-orientador: Luiz Albino Teixeira Júnior.

Bibliografia: p. 118-124.

1. Análise de séries temporais. 2. Piezômetro. 3. Barragens e açudes - Segurança - Modelos econométricos. 4. Wavelets (Matemática). 5. redes neurais (Computação). I. Universidade Federal do Paraná. II. Scarpin, Cassius Tadeu. III. Teixeira Júnior, Luiz Albino. IV. Título.


CDD: 627.80289

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da Tese de Doutorado de ELIETE NASCIMENTO PEREIRA, intitulada: "Proposta de Modelo Híbrido Composta por Wavelet, Arima e Redes Neurais Artificiais de Funções de Bases Radiais para Previsão de Séries Temporais: Uma Aplicação em um Instrumento da Barragem de Itaipu", após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua

APROVAÇÃO.

Curitiba, 14 de Abril de 2016.



Prof CASSIUS TADEU SCARPIN (UFPR)
(Presidente da Banca Examinadora)




Prof ANSELMO CHAVES NETO (UFPR)



Prof JULIO CÉSAR NIEVOLA (PUC/PR)



Prof MARIA TERESINHA ARNS STEINER (UFPR)



Prof THIAGO ANDRE GUIMARAES (IFPR)

Curitiba, 14 de abril de 2016

Em memória de meu pai Eduardo.

Dedico a minha mãe Leni, a minha irmã Eliane e aos meus sobrinhos Bruna e Humberto, por sempre estarem presentes em minha vida.

Também dedico ao meu orientador Cassius, por compartilhar seu conhecimento.

AGRADECIMENTOS

Agradeço a Deus, pelo fôlego de vida, pela minha família e pelas oportunidades concedidas, que me fizeram enxergar meus limites.

Ao meu orientador Cassius e coorientador Luíz pela paciência, pelas ideias e por sempre estarem dispostos a me ajudar.

Agradeço a minha família de sangue e as famílias que conheci durante essa caminhada, família IBR de Foz do Iguaçu, família PIB de Curitiba, obrigada pela amizade e orações, a família GTA O pelo apoio e ajuda sempre que precisava.

A família Dinter Foz do Iguaçu, que estava sempre unida ajudando uns aos outros. Queria agradecer especialmente a Fabiana, Sheila, Tereza, Adriana e ao doutor Geraldo que sempre estava animado.

Ao meu amigo e irmão Cleverson dos Santos e sua esposa, por me acolherem nos finais de semana para estudar para a prova de qualificação.

A minha amiga Cecília e a família Locatteli por propiciar a minha estadia em Curitiba.

A engenheira da Usina Hidrelétrica de Itaipu Silvia Frazão, que forneceu os dados de Itaipu, me ensinou e auxiliou no entendimento sobre o assunto segurança e monitoramento de barragens.

Ao Adriano e Juliano Motta pela ajuda com o Matlab.

Agradeço também as instituições envolvidas neste Dinter, UFPR, Unioeste ao PPGMNE, Ceasb, Usina Hidrelétrica de Itaipu.

A professora Neida, pois sem ela não teria sido possível a implementação da bolsa que recebi, agradeço também a Fundação Araucária e a Capes pela bolsa de estudos concedida.

A professora Liliana e ao professor Anselmo que não mediram esforços para que o Dinter desse certo.

Para terminar agradeço a minha irmã Eliane, por ser incisiva comigo em momentos cruciais, um deles em insistir que procurasse ajuda psicológica. Graças a ela conheci a psicóloga Michelle Bronzatti, que vem me colocando nos eixos e me mostrando que os limites devem ser trabalhados e não ignorados.

"E sabemos que todas as coisas contribuem juntamente para o bem daqueles que amam a Deus"

Romanos 8:28

RESUMO

A previsão de séries temporais é empregada em várias áreas de conhecimento. O presente estudo tem como foco auxiliar, a partir de previsões de séries temporais, a tomada de decisão da equipe responsável do monitoramento e segurança de barragens na Usina Hidrelétrica de Itaipu no Paraná. Busca-se melhorar a assertividade das previsões por meio de uma metodologia híbrida composta das técnicas de Box e Jenkins (método ARIMA), das Redes Neurais Artificiais de Funções de Bases Radiais e da Decomposição *Wavelet*. As três técnicas são associadas de forma única gerando ajustes de teste e previsões que são similares e, por vezes, com erros menores do que os modelos híbridos da literatura, como Zhang (2003); Khashei e Bijari (2011). A inovação da metodologia elaborada neste trabalho se dá em relação a estrutura e a forma de compor a combinação das técnicas. Dado que o tipo de *Wavelet* influencia nas previsões, desenvolveu-se uma lógica elementar para a sua escolha. As séries temporais consagradas na literatura, dos Lincos Canadenses, das Manchas Solares e da Taxa de Câmbio, são aplicadas na metodologia proposta visando determinar a melhor configuração. Esta configuração obtida foi utilizada para a aplicação na série do Piezômetro, instrumento que monitora a subpressão da Usina Hidrelétrica de Itaipu. Foi realizado o ajuste de teste (quando se faz a aplicação do método um passo a frente, empregando os dados originais da série referente ao conjunto de teste) e previsão (quando a aplicação do método resulta em valores futuros e estes são empregados para a obtenção das próximas previsões). Os resultados obtidos, considerando o ajuste de teste da série temporal, em relação às séries da literatura foram comparados aos resultados publicados e verificou-se que nas três séries testadas a metodologia proposta obteve melhor desempenho. No que se refere a previsões destaca-se o resultado da série da Taxa de Câmbio, a qual tinha como melhor resultado da literatura um erro MSE de $3,648 \times 10^{-5}$ em Khashei e Bijari (2011), sem a utilização da Decomposição *Wavelet* (DW); com a metodologia proposta, realizando a DW, obteve-se um MSE de $1,943 \times 10^{-6}$. No que diz respeito a série do Piezômetro da Usina Hidrelétrica de Itaipu pode-se verificar que o erro MSE de 0,086, é menor em relação aos modelos ARIMA e Rede Neural de Função de Bases Radiais.

Palavras-chave: Modelo Híbrido. Previsão de Séries Temporais. Piezômetro. Monitoramento e Segurança de Barragem. Decomposição *Wavelet*. Redes Neurais Artificiais. ARIMA.

ABSTRACT

The time series forecasting is used in various fields of knowledge. The focus of this study is to support the decision making from time-series forecasting, by the committee responsible for monitoring of dam safety in the Itaipu hydroelectric dam on the Paraná. Searching to improve the assertiveness of forecasts by a hybrid methodology consists of the techniques of Box and Jenkins (ARIMA method), the Artificial Neural Networks Radial Basis Functions and Wavelet Decomposition. The three techniques are uniquely associated with generating test settings and predictions which are similar to and sometimes better than the hybrid models from the literature, such as Zhang (2003); Khashei and Bijari (2011). The innovation of the methodology developed in this work is given regarding the structure and form to compose a combination of techniques. Given that kind of influence on Wavelet forecasting, developed an elementary logic to the choice. The time series usually used in literature, Canadian Lynx, Wolf's Sunspot and Exchange Rates are applied in the proposed methodology to determine the best configuration. This configuration obtained was used for the application in the Piezometer series instrument that monitors the underpressure of the Itaipu hydroelectric dam. It conducted the test adjustment (when do the method a step ahead, using the original data series regarding the test set) and forecast (when the application of the method results in future values and these are employees to obtain the next estimates). The results obtained, considering the time series test setting, in relation to the series in the literature were compared to the published results and found that the three series tested the proposed method performed better. As regards the highlight the estimates is the result series Exchange rate, which had the best result literature $3,648 \times 10^{-5}$ MSE error by Khashei and Bijari (2011), without the Wavelet Decomposition; the proposed method with the Wavelet Decomposition, was obtained MSE of $1,943 \times 10^{-6}$. Regarding the Itaipu hydroelectric dam piezometer series can be seen which the MSE error of 0.086 is lower compared to ARIMA and Neural Network Radial Basis Function models.

Keywords: Hybrid Model of time series forecasting. Piezometer. Monitoring and Dam Safety. Artificial Neural Network. ARIMA.

LISTA DE FIGURAS

FIGURA 2.1 - RELAÇÃO ENTRE OS TIPOS DE INSTRUMENTOS E A DETERIORAÇÃO DE BARRAGENS DE CONCRETO.....	27
FIGURA 2.2 - SEÇÃO GEOLÓGICA TÍPICA DE USINA HIDRELÉTRICA DE ITAIPU 29	
FIGURA 2.3 - CONDIÇÕES DE CARGAS BÁSICAS E FORMAS DE INSTABILIDADE DE BARRAGENS DE GRAVIDADE DE CONCRETO 30	
FIGURA 2.4 - PIEZÔMETRO STANDPIPE.....	30
FIGURA 3.1 - CARACTERÍSTICAS DA SÉRIE TEMPORAL E MODELOS DE PREVISÃO.....	33
FIGURA 3.2 - NÚMERO DE PUBLICAÇÕES POR ANO.....	34
FIGURA 3.3 - NÚMERO DE PUBLICAÇÕES POR REVISTA	34
FIGURA 3.4 - DISTRIBUIÇÃO TEMPORAL DE CITAÇÕES.	35
FIGURA 3.5 - PREVISÕES REALIZADAS POR ZHANG (2003) AO CONJUNTO TESTE DA SÉRIE DOS LINES CANADENSES.....	45
FIGURA 3.6 - PREVISÕES REALIZADAS POR ZHANG (2003) AO CONJUNTO DE TESTE DA SÉRIE DAS MANCHAS SOLARES	46
FIGURA 3.7 - PREVISÕES REALIZADA POR ZHANG (2013) PARA A SÉRIE DA TAXA DE CÂMBIO.....	47
FIGURA 3.8 - PREVISÃO DO MODELO PROPOSTO POR KHASHEI E BIJARI (2011) PARA O CONJUNTO DE TESTE	49
FIGURA 3.9 - ESTRUTURA DA RNA-RBF	56
FIGURA 3.10 - ESTRUTURA HAAR.....	63
FIGURA 4.1 - SÉRIE TEMPORAL DOS LINES CANADENSES	68
FIGURA 4.2 -LOGARITMO DA SÉRIE DOS LINES CANADENSES	69
FIGURA 4.3 -SÉRIE TEMPORAL DE MANCHAS SOLARES.....	70
FIGURA 4.4 - SÉRIE TEMPORAL DA TAXA DE CÂMBIO.....	71
FIGURA 4.5 - LOCALIZAÇÃO DO PIEZÔMETRO PS-F-72	72
FIGURA 4.6 - SÉRIE MANUAL SUAVIZADA DO PIEZÔMETRO PS-F-72.....	73
FIGURA 4.7 - METODOLOGIA PROPOSTA HÍBRIDA 1.....	76
FIGURA 4.8 - METODOLOGIA PROPOSTA HÍBRIDA 2.....	78

FIGURA 5.1 - MODELAGEM ARIMA APLICADA AO CONJUNTO DE TESTE A_2 DOS LINES CANADENSES.....	82
FIGURA 5.2 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_1 DOS LINES CANADENSES.....	83
FIGURA 5.3 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_2 DOS LINES CANADENSES.....	83
FIGURA 5.4 - RESULTADO DA METODOLOGIA 1 PARA O CONJUNTO DE TESTE DA SÉRIE DOS LINES CANADENSES	85
FIGURA 5.5 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DOS LINES CANADENSES.....	88
FIGURA 5.6 - PREVISÃO N PASSOS A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DOS LINES CANADENSES.....	88
FIGURA 5.7 - PREVISÃO AR(12) DO CONJUNTO DE TESTE DA SÉRIE DOS LINES CANADENSES.....	89
FIGURA 5.8 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE A_2 DA SÉRIE DE MANCHAS SOLARES.....	92
FIGURA 5.9 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_1 DA SÉRIE DE MANCHAS SOLARES.....	92
FIGURA 5.10 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_2 DA SÉRIE DAS MANCHAS SOLARES	93
FIGURA 5.11 - PREVISÃO DO CONJUNTO DE TESTE DA METODOLOGIA 1 DA SÉRIE DAS MANCHAS SOLARES	95
FIGURA 5.12 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DAS MANCHAS SOLARES.....	97
FIGURA 5.13 - PREVISÃO N PASSOS A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DAS MANCHAS SOLARES.....	98
FIGURA 5.14 - PREVISÕES AR(9) DO CONJUNTO DE TESTE DAS MANCHAS SOLARES	98
FIGURA 5.15 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE A_2 DA SÉRIE DA TAXA DE CÂMBIO	101
FIGURA 5.16 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_1 DA SÉRIE DA TAXA DE CÂMBIO	102

FIGURA 5.17 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_2 DA SÉRIE DA TAXA DE CâMBIO	102
FIGURA 5.18 - PREVISÃO DO CONJUNTO DE TESTE DA METODOLOGIA 1 DA SÉRIE DA TAXA DE CâMBIO	104
FIGURA 5.19 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DA TAXA DE CâMBIO.....	106
FIGURA 5.20 - PREVISÃO N PASSOS A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DA TAXA DE CÂMBIO.....	107
FIGURA 5.21 - PREVISÃO DINÂMICA 1 PASSO A FRENTE DO CONJUNTO DE TESTE DA SÉRIE PS-F-72 PARA MODELOS CLÁSSICOS.....	111
FIGURA 5.22 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE PS-F-72.....	111

LISTA DE TABELA

TABELA 5.1 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DOS LINES CANADENSES.....	90
TABELA 5.2 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DAS MANCHAS SOLARES.....	99
TABELA 5.3 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DA TAXA DE CÂMBIO.....	108
TABELA 5.4 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DO PIEZÔMETRO PS-F-72.....	112
TABELA 5.5 - MELHORES RESULTADOS DE PREVISÃO PARA AS SÉRIES ESTUDADAS	112

LISTA DE QUADROS

QUADRO 3.1 - COMPOSIÇÃO DAS AMOSTRAS EM TRÊS CONJUNTOS DE DADOS	43
QUADRO 3.2 - ESTRUTURA DA RNA-MLP UTILIZADA NO MODELO HÍBRIDO DE KHASHEI E BIJARI (2011)	48
QUADRO 3.3 - TIPOS DE SÉRIES ESTUDADAS NA LITERATURA.....	52
QUADRO 3.4 - EXEMPLO DE DECOMPOSIÇÃO <i>WAVELET</i> HAAR.....	63
QUADRO 3.5 - EXEMPLO DE DECOMPOSIÇÃO <i>WAVELET</i> DB2.....	64
QUADRO 5.1 - IDENTIFICAÇÃO DAS <i>WAVELETS</i> UTILIZADAS	80
QUADRO 5.2 - MODELO ARIMA DAS COMPONENTES <i>WAVELET</i> DA SÉRIE LINCES CANADENSES	81
QUADRO 5.3 - ESTRUTURA DA RNA DA METODOLOGIA 1 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DOS LINCES CANADENSES	84
QUADRO 5.4 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DOS LINCES CANADENSES	86
QUADRO 5.5 - MODELOS DE PREVISÃO DA METODOLOGIA 2 PARA A SÉRIE DOS LINCES CANADENSES.....	87
QUADRO 5.6 - MODELO ARIMA DAS COMPONENTES <i>WAVELET</i> DA SÉRIE MANCHAS SOLARES	91
QUADRO 5.7 - ESTRUTURA DA RNA DA METODOLOGIA 1 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DAS MANCHAS SOLARES	94
QUADRO 5.8 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DAS MANCHAS SOLARES	96
QUADRO 5.9 - MODELOS DE PREVISÃO DA METODOLOGIA 2 PARA A SÉRIE DAS MANCHAS SOLARES.....	96
QUADRO 5.10 - MODELO ARIMA DAS COMPONENTES <i>WAVELET</i> DA SÉRIE DA TAXA DE CÂMBIO	100

QUADRO 5.11 - ESTRUTURA DA RNA DA METODOLOGIA 1 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DA TAXA DE CâMBIO	103
QUADRO 5.12 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DA TAXA DE CâMBIO	105
QUADRO 5.13 - MODELOS DE PREVISÃO DA METODOLOGIA 2 PARA A SÉRIE DE TAXA DE CâMBIO	105
QUADRO 5.14 - MODELO ARIMA DAS COMPONENTES WAVELET DA SÉRIE PS- F-72	109
QUADRO 5.15 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE PS-F-72	110

LISTA DE SIGLAS

AR	-	<i>Autoregressive</i> (Autorregressivo)
ARCH	-	<i>Autoregressive Conditional Heterocedasticity</i>
ARMA	-	<i>Autoregressive Moving Average</i> (Autorregressivo médias móveis)
ARIMA	-	<i>Autoregressive Integrated Moving Average</i> (Autorregressivo Intergrado Médias Móveis)
CEASB	-	Centro de Estudos Avançados de Segurança de Barragens
Cna	-	Cota do Nível de água
CWA	-	Combinação Wavelet ARIMA
CWAN	-	Combinação <i>Wavelet</i> ARIMA NEURAL
DW	-	Decomposição <i>Wavelet</i>
DTI	-	Diretoria Técnica de Itaipu
FAC	-	Função de autocorrelação
FACP	-	Função de autocorrelação parcial
FACV	-	Função de autocovariância
GA	-	<i>Genetic Algorithm</i> (Algoritmo Genético)
GKMA	-	<i>Genetic k-Means Algorithm</i> (Algoritmo k-Médias Genético)
ICOLD	-	<i>International Commission of Large Dams</i>
KMA	-	<i>k-Means Algorithm</i> (K-médias)
MA	-	<i>Moving Average</i> (Médias Móveis)
MAPE	-	<i>Mean Absolute Percentage Error</i> (Erro médio percentual absoluto)
Mca	-	Metros de coluna d'água
MLP	-	<i>Multilayer Perceptrons</i>
MSE	-	<i>Mean Squared Error</i> (erro quadrático médio)
Msnm	-	Metros sobre o nível do mar
OLS	-	<i>Orthogonal Least Squares</i> (Mínimos Quadrados Ortogonais)
PE	-	Processo Estocástico
PSO	-	<i>Particle Swarm Optimization</i>
RBF	-	<i>Radial Basis Function</i> (Funções de bases radiais)
RMSE	-	<i>Root Mean Squared Error</i> (Raiz do erro quadrático médio)
RNA	-	Redes Neurais Artificiais

SA	-	<i>Simulated Annealing</i>
SSE	-	<i>Sum of Squared Error</i> (Soma dos erros quadráticos)
SHM	-	<i>Structural health monitoring</i> (monitoramento da saúde estrutural)
SOM	-	<i>Self-Organizing Map</i> (Mapas Auto-Organizáveis)
SVM	-	<i>Support Vector Machines</i>
SVR	-	<i>Support Vector Regression</i>
TDNN	-	<i>Time Delay Neural Networks</i>

SUMÁRIO

1	INTRODUÇÃO	19
1.1	OBJETIVO DO TRABALHO	23
1.1.1	Objetivo geral	23
1.1.2	Objetivos específicos	23
1.2	IMPORTÂNCIA DO TRABALHO	24
1.3	LIMITAÇÕES DO TRABALHO	24
1.4	ESTRUTURA DO TRABALHO	25
2	DESCRIÇÃO DO PROBLEMA	26
3	REVISÃO DA LITERATURA	32
3.1	PANORAMA GERAL DE MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS	32
3.2	TRANSFORMAÇÕES WAVELET APLICADA A SÉRIES TEMPORAIS	35
3.3	MÉTODOS DE PREVISÃO	38
3.3.1	Métodos acoplados a modelos de previsão de séries temporais	38
3.3.2	Modelos híbridos de previsão de séries temporais	41
3.4	TRABALHOS CORRELATOS RELACIONADOS A METODOLOGIA PROPOSTA	43
3.5	FUNDAMENTAÇÃO TEÓRICA	50
3.5.1	Séries temporais	50
3.5.2	Método ARIMA	52
3.5.3	Redes neurais artificiais	54
3.5.4	Transformação <i>Wavelet</i>	60
3.5.5	Métodos de comparação	65
4	MATERIAIS E MÉTODOS	67
4.1	SÉRIES TEMPORAIS UTILIZADAS	67
4.1.1	Série temporal dos lincas canadenses	68
4.1.2	Série temporal de Manchas Solares de Wolf	69
4.1.3	Série temporal da Taxa de Câmbio	70
4.1.4	Série temporal do piezômetro PS-F-72	71
4.2	MÉTODOS HÍBRIDOS PROPOSTOS	74
5	RESULTADOS E DISCUSSÕES	80

5.1	METODOLOGIAS PROPOSTAS APLICADAS A SÉRIE DOS LINCES CANADENSES	81
5.1.1	Metodologia 1 aplicada a série dos Lincos Canadenses	84
5.1.2	Metodologia 2 aplicada a série dos Lincos Canadenses	86
5.2	METODOLOGIAS PROPOSTAS APLICADAS A SÉRIE DAS MANCHAS SOLARES WOLF	90
5.2.1	Metodologia 1 aplicada a série das Manchas Solares	93
5.2.2	Metodologia 2 aplicada a série das Manchas Solares	95
5.3	METODOLOGIAS PROPOSTAS APLICADAS A SÉRIE DA TAXA DE CÂMBIO	100
5.3.1	Metodologia 1 aplicada a série da Taxa de Câmbio	103
5.3.2	Metodologia 2 aplicada a série da Taxa de Câmbio	104
5.4	METODOLOGIA PROPOSTA APLICADA A SÉRIE DO PIEZOMETRO PS-F-72	108
6	CONCLUSÃO E CONSIDERAÇÕES FINAIS	114
7	REFERÊNCIAS	117
	APÊNDICE 1 - WAVELETS ADOTADAS NO ESTUDO	124
	ANEXO 1 - INSTRUMENTOS INSTALADOS NA USINA HIDRELÉTRICA DE ITAIPU	127

1 INTRODUÇÃO

A Usina Hidrelétrica de Itaipu é uma das maiores do mundo em produção de energia. A magnitude e complexidade de seu projeto, execução e funcionamento a tornam um ícone de engenhosidade segundo a Diretoria Técnica de Itaipu (DTI, 2009). Em 2013 com a produção anual de energia de 98,6 milhões de *MWh* obteve o recorde mundial, a usina de Três Gargantas na China obteve o recorde mundial em 2014 produzindo 98,8 milhões de *MWh*. Em relação ao total de energia produzida pela Usina Hidrelétrica de Itaipu 92% é destinada ao Brasil (equivalente a 20% do total necessário no Brasil) e 8% restante destinada ao Paraguai (94% da demanda do país) (SEDT; SCS, 2008). Para assegurar sua integridade estrutural, foi realizado um grande projeto de monitoramento de toda a barragem e fundação.

A Usina Hidrelétrica de Itaipu possui blocos específicos, onde a instrumentação é completa, denominados blocos chaves. Estes blocos foram selecionados por sua altura, localização e condições especiais de fundações, onde vários tipos de instrumentos foram instalados. Os equipamentos instalados são capazes de monitorar os seguintes parâmetros da fundação: subpressão, vazão de infiltração, deformações; das estruturas: deslocamentos absolutos e relativos, tensões, deformações e temperatura.

A fundação é composta por vários derrames basálticos, a interação entre eles e suas características podem acarretar deslizamentos, tombamentos, flutuação, tensões na base da fundação e na estrutura, deformações, recalques e vibrações, segundo Villwock (2009). Por meio das leituras coletadas pela instrumentação, é possível identificar causas e consequências de determinadas reações da fundação, permitindo a realização de manutenções preventivas e aumentando, com isso, a segurança da barragem e de sua vida útil. O monitoramento da "saúde estrutural" de uma barragem pode evitar tragédias como observado em: Pampulha em 1954, Orós em 1960, Euclides da Cunha e Sales de Oliveira em 1977, Camará em 2004, Apertadinho em 2008, Algodões I em 2009, esses e outros casos inclusive internacionais, são tratados em Veról (2010). O desastre ocorrido na barragem da mineradora Samarco em 2015 em Minas Gerais foi um exemplo de que o monitoramento de uma barragem é extremamente importante.

A instrumentação de auscultação^{1,2} da Usina Hidrelétrica de Itaipu conta com mais de 2300 instrumentos. Estes geram uma grande quantidade de dados espaçados no tempo (séries temporais) (SEDT; SCS, 2008). Existem instrumentos com leituras desde o início da construção da barragem em 1975. Nesta época, os dados eram extraídos apenas manualmente. A princípio as leituras eram observadas em uma frequência maior na fase de construção; depois da completa construção da hidrelétrica e da estabilização desta, a frequência de leitura dos instrumentos foi reduzida. A usina atualmente possui 10% de seus instrumentos com medidas automatizadas.

A equipe responsável pelo monitoramento e segurança da barragem, com base nos dados observados, ao identificar algum comportamento anômalo nas séries históricas, analisam a necessidade de medidas preventivas ou corretivas. Caso dispusessem de uma previsão confiável da série temporal de um dado instrumento, seria possível averiguar de forma mais imediata o comportamento atípico e, caso fosse realmente necessário, antecipar o planejamento da manutenção.

Há, na literatura, diversos métodos de previsão de séries temporais. Destacam-se a metodologia Box e Jenkins, Box et al. (2008), que é robusta e capaz de modelar dados que possuem características lineares e estacionárias e as Redes Neurais Artificiais (RNA) que também são utilizadas para este fim e, ainda, são capazes de modelar dados que possuem relações complexas não lineares.

A Decomposição *Wavelet* (DW) é uma metodologia que pode ser utilizada para aprimorar os resultados obtidos dos métodos de previsão citadas acima. De acordo com Lima (2002), este método decompõe a série em partes, possibilitando a análise dos dados em vários domínios. Isto é realizado hierarquicamente descrevendo a série temporal em uma forma “grosseira” e outra “fina”. Esta separação visa diferenciar características menos sutis e mais refinadas, sendo efetuadas como pré-processamento da série em relação aos métodos de previsão.

Uma vez que a aplicação da DW tem se tornada promissora na previsão de séries temporais, como pode se averiguar nos trabalhos de Adamowski; Chan (2011), Caswell (2014), Seo et al. (2015), Maheswaran; Khosa (2015) na presente

¹ A auscultação é o conjunto de formas de observação do comportamento da barragem e fundações, para controlar suas condições de segurança, comprovar a validade das hipóteses e dos métodos de cálculos utilizados no projeto e verificar a necessidade de medidas corretivas.

² <https://www.itaipu.gov.br/energia/auscultacao>

proposta, a série original será decomposta com a finalidade de ajudar no aprimoramento da previsão da série.

Modelos híbridos ou combinações de vários métodos têm se tornado um artifício comum, de acordo com Khashei e Bijari (2011). O propósito destes é diminuir o risco de se empregar um método previsão inapropriado a série e aumentar a assertividade das previsões. Isso se deve a capacidade de captar características lineares e não lineares dos dados. Entretanto alguns trabalhos assumem que a relação entre os modelos é aditiva (ZHU et al., 2014, KIA et al., 2012, VALENZUELA et al., 2008 e ZHANG, 2003).

Os modelos híbridos têm como motivação, primeiramente, a dificuldade em se determinar a estrutura de dependência da série estudada (linear ou não linear). A segunda motivação é que séries temporais reais raramente possuem exclusivamente características lineares ou não lineares e, geralmente, é uma combinação de ambos os padrões. O terceiro motivo é aceitação dos modelos híbridos na área de previsão. Devido aos problemas reais serem normalmente compostos por uma natureza complexa, a aplicação de um único modelo pode não ser capaz de captar suas diferentes características.

A intenção deste trabalho é apresentar uma proposta, para o desenvolvimento de um modelo híbrido composto por DW, modelos *Autoregressive Integrated Moving Average* (ARIMA) (Autorregressivos Integrados Médias Móveis) e RNA *Radial Basis Function* (RBF- Funções de Bases Radiais). Este modelo poderá ser aplicado a séries tanto estacionárias como não estacionárias, que possuem relações lineares ou não entre seus dados.

A metodologia proposta foi motivada pela aplicação na série inicial de um instrumento específico da Usina Hidrelétrica de Itaipu, o piezômetro. A DW realiza o pré-processamento dos dados; tendo como resultado a decomposição da série original em outras séries, chamadas de aproximação e detalhes. Estas séries decompostas são modeladas pelo método ARIMA, que apreenderá as características lineares da série.

O ajuste de cada série do modelo ARIMA é combinado linearmente, a fim de compor a previsão da série inicial. Os pesos dessa combinação são definidos através de um Problema de Programação Não Linear, algo que não é empregado nos trabalhos referentes aos modelos híbridos encontrados na literatura.

Deste ajuste obtém-se o resíduo, diferença entre os dados originais e os valores ajustados pelo modelo ARIMA. O tratamento dos resíduos do ajuste e treinamento também é realizado pela DW, visando melhorar seu ajuste à RNA-RBF. Na literatura são observados resultados adequados com a modelagem dos resíduos através da RNA-RBF, como pode ser observado no trabalho de Zheng e Zhong (2011). Busca-se nesta fase modelar características não lineares que a série ainda pode apresentar, contribuindo, assim, na previsão da série inicial ou original. A composição dos ajustes dos resíduos é realizada da mesma forma que anteriormente. Por fim, faz-se a composição entre os valores previstos inicialmente com os valores previstos dos resíduos, obtendo-se a previsão final, ao invés de uma simples soma de previsões.

Coelho e Santos (2011), Jiurian e Bingfeng (2013), a fim de melhorar a previsão obtida, empregam a combinação do método ARIMA e RNA.

Os resultados são analisados em relação ao ajuste e previsão do conjunto de teste.

Define-se como ajuste de teste ao resultado obtido quando os padrões de teste são compostos apenas por dados da série inicial, por exemplo, o primeiro padrão de teste gera uma previsão, a janela de previsão desloca-se um passo em relação aos dados de teste e é apresentado ao modelo que fornece a previsão do dado seguinte, assim por diante até que todos os padrões do conjunto de teste sejam utilizados.

A previsão do conjunto de teste é realizada quando a previsão do primeiro padrão é utilizada no segundo padrão ao invés do dado original, a previsão do primeiro e segundo é utilizada para a previsão da terceira, assim sucessivamente até que todos os padrões de teste sejam apresentados ao modelo. A previsão ainda é diferenciada em um passo e n passos à frente, a primeira faz a previsão do dado subsequente ao último que forma o padrão; a segunda faz a previsão de todos os dados ao mesmo tempo em relação ao horizonte de previsão n .

1.1 OBJETIVO DO TRABALHO

A fim de definir os objetivos deste trabalho apresenta-se o objetivo geral e os objetivos específicos

1.1.1 Objetivo geral

Desenvolver dois métodos híbridos de previsão de séries temporais, sendo que um método possibilita apenas a previsão n passos a frente e o outro realiza a previsão um passo e n passos à frente, sendo que n é definido especificamente em relação ao horizonte de tempo que se almeja prever. As duas metodologias são compostas por Decomposição *Wavelet*, ARIMA e Redes Neurais Artificiais de Funções de Bases Radiais. A diferença entre elas está no resíduo utilizado, na modelagem aplicada a eles e na composição da combinação da previsão final.

1.1.2 Objetivos específicos

A fim de que o objetivo geral seja alcançado, faz-se necessário satisfazer os seguintes objetivos específicos:

- Fazer o levantamento do referencial teórico a respeito de técnicas híbridas de previsão de séries temporais;
- Definir metodologias híbridas de previsão de séries temporais, combinando métodos estatísticos e de inteligência artificial;
- Realizar o ajuste da série utilizando as metodologias, considerando três séries da literatura;
- Realizar a previsão um passo e n passos à frente utilizando as metodologias, considerando três séries da literatura;
- Comparar os resultados obtidos aos da literatura;

- Realizar a suavização da série do Piezômetro da Usina hidrelétrica de Itaipu, por meio do cálculo da média mensal das leituras do instrumento;
- Identificar a metodologia que produz o melhor resultado, dentre as propostas, para a previsão e aplicá-la a série temporal do Piezômetro da Usina Hidrelétrica Itaipu.

1.2 IMPORTÂNCIA DO TRABALHO

A importância deste projeto está relacionada a duas perspectivas:

- Desenvolvimento de um modelo híbrido de previsão de séries temporais que possa alcançar o menor erro de previsão, se comparado à métodos apresentados na literatura;
- Aplicação da metodologia à série temporal real da Usina Hidrelétrica de Itaipu. Busca-se apresentar uma técnica de auxílio ao monitoramento de barragem, pois assim pretende-se proporcionar o conhecimento prévio das leituras dos instrumentos. Deseja-se com isto, antecipar a tomada de decisões pelo especialista em segurança de barragem.

1.3 LIMITAÇÕES DO TRABALHO

A aplicação de métodos híbridos de previsão é indicada a séries que possuem autodependência linear e não linear, sendo assim se limita a séries com essa característica.

Também se limita a aplicar em apenas uma série de um instrumento localizado no bloco F 19/20 da barragem da Usina Hidrelétrica de Itaipu. Esta limitação se dá pela disponibilidade dos dados por parte dos técnicos da barragem da Usina Hidrelétrica de Itaipu.

1.4 ESTRUTURA DO TRABALHO

O trabalho está organizado da seguinte maneira.

No capítulo 2 faz-se a abordagem do problema a ser estudado, apresentando-se o tema de monitoramento e segurança de barragens. Neste capítulo também define-se o instrumento específico utilizado na aplicação do modelo.

No capítulo 3 apresenta-se a revisão pertinente ao assunto, contendo trabalhos correlatos e o referencial teórico das técnicas que serão utilizados.

No capítulo 4 expõem-se todas as séries que são utilizadas e a metodologia proposta.

No capítulo 5 são apresentados os resultados e discussões.

A conclusão e sugestões de trabalhos futuros são expostos no capítulo 6.

2 DESCRIÇÃO DO PROBLEMA

O monitoramento da saúde estrutural (*Structural health monitoring, SHM*) de uma obra de engenharia, refere-se a processos de implementação estratégicos para identificação de danos. Modificações ocorridas na estrutura, material ou geometria do objeto em questão são consideradas danos. A Norma NBR 8681(2003) estipula as ações e segurança nas estruturas civis e a Lei nº 12.334 (2010) estabelece a política nacional de segurança de barragens.

O número de pesquisas sobre o tema vem crescendo a cada ano pelo fato de preservar a segurança da vida da população ao redor da estrutura, além de ter como consequência benefícios econômicos (FARRAR e WORDEN, 2007; VILLWOCK, 2009; GUANG-YONG et al., 2011; BUKENYA et al., 2014). Para que o monitoramento seja efetivo utilizam-se instrumentos para averiguar características importantes em relação à estrutura a ser avaliada (MATOS, 2002).

A pesquisa sobre segurança estrutural de barragens foi um dos motivadores para a criação do *International Commission of Large Dams* (ICOLD - Comissão Internacional de Grandes Barragens), ratificando esse interesse. Essa associação promove a disseminação de informações sobre: falhas ocorridas, melhoria de técnicas de investigação e divulgação de riscos inerentes a esse tipo de construção, evidenciando a importância da inspeção e supervisão contínua durante toda a vida da barragem (ICOLD, 2015)

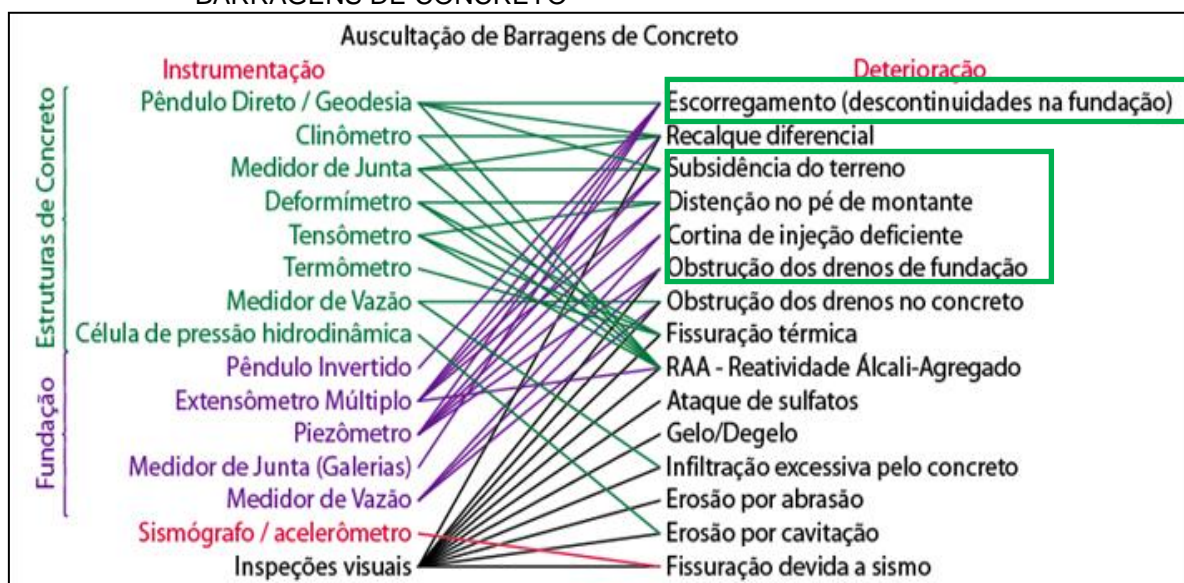
A utilização de instrumentação proporciona a auscultação das condições estruturais da barragem. Esse monitoramento promove uma compreensão da estrutura, auxiliando então na descoberta de situações críticas. Isso ocasiona o aumento da segurança da barragem, pois pode-se identificar a necessidade de manutenções, ações corretivas e preventivas. Entretanto, para qualquer ação ser implementada, ela deve se basear em planos previamente elaborados na fase de construção da barragem (KUPERMAN et al., 2003, SILVEIRA, 2003).

A partir da identificação da característica que se quer investigar é possível definir o instrumento a ser utilizado no monitoramento. Entre as características, pode-se citar: a pressão da água nos poros, a pressão da água na rocha da fundação, as pressões totais, os recalques, os deslocamentos horizontais, as cargas

e tensão nos elementos estruturais, a temperatura, as vazões de drenagem, os materiais sólidos careados, entre outros (BUZZI et al., 2007).

Na Figura 2.1 apresenta-se os instrumentos e suas relações com as características da estrutura de concreto e fundação. O piezômetro, por exemplo, está relacionado com a obstrução dos drenos no concreto, cortina de injeção deficiente, distensão no pé de montante, subsidência do terreno e escorregamento (descontinuidades na fundação).

FIGURA 2.1 - RELAÇÃO ENTRE OS TIPOS DE INSTRUMENTOS E A DETERIORAÇÃO DE BARRAGENS DE CONCRETO



FONTE: Modificado Silveira (2003).

A Usina Hidrelétrica de Itaipu possui um total de mais de 2300 instrumentos de auscultação, que estão instalados em vários trechos da barragem como pode ser observado no Anexo 1, mas existem alguns blocos denominados blocos chaves, que se distinguem pela sua importância ou condição especial. Esses blocos receberam um conjunto completo de instrumentos. Adicionalmente às leituras da instrumentação são realizadas inspeções visuais, para constatar possíveis circunstâncias atípicas nestes blocos. Relatórios a respeito do desempenho das estruturas e da fundação são organizados duas vezes ao ano.


A fundação da barragem da Usina Hidrelétrica de Itaipu é composta por várias camadas e interfaces. Ela possui as seguintes características geológicas, segundo DTI (2009):

- Derrames basálticos, de 30 a 70 metros de espessura, são cinco derrames relativamente uniformes, denotados pelas letras do alfabeto de A à E na Figura 2.2;
- Basalto denso possui alto módulo de deformidade e altamente fraturado;
- Basalto vesículo-amigdaloidal, como o nome já indica possui vesículas é menos fraturado que o anterior e não apresenta zonas permeáveis;
- Camadas de brecha intercaladas entre derrames de basalto, com elevada porosidade e interconexões de cavidades;
- Descontinuidades em planos paralelos aos derrames;
- Permeabilidade horizontal maior que a permeabilidade vertical.

A disposição das camadas acima citadas, na fundação da Usina Hidrelétrica de Itaipu, pode ser observada na Figura 2.2.

Uma investigação geológica e geotécnica foi realizada a fim de assegurar a fundação adequada para as estruturas da barragem. Em algumas áreas foi necessário o tratamento subterrâneo, o que melhorou suficientemente os coeficientes de segurança contra o cisalhamento-deslizamento na descontinuidade encontrada, tornando-os adequados. O monitoramento da fundação informa seus deslocamentos horizontais e verticais auxiliando a avaliação do desempenho e estabilidade estrutural da barragem, SEDT; SCS (2008).

FIGURA 2.2 - SEÇÃO GEOLÓGICA TÍPICA DA USINA HIDRELÉTRICA DE ITAIPU

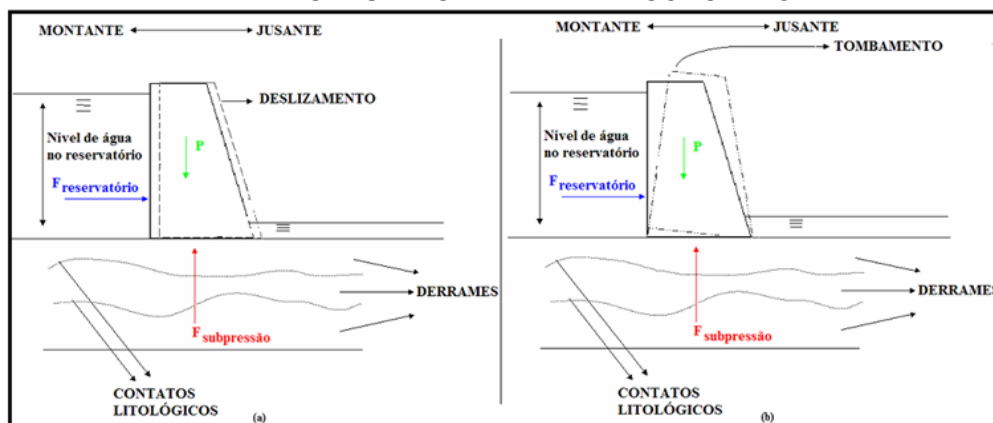


FONTE: SEDT; SCS (2008).

Uma cortina de injeção foi aplicada, para isolar a área de fundação dos blocos maiores da barragem principal da Usina Hidrelétrica de Itaipu. Sistemas de drenagem foram construídos para reduzir as subpressões, predominantemente nas zonas fraturadas ou em descontinuidades permeáveis, pelo fato de existir a possibilidade de fluxo de infiltração dentro da área da barragem. A drenagem é importante em virtude de possível deslizamento ao longo das descontinuidades, em áreas que este tratamento é empregado devem-se ter níveis piezométricos abaixo da cota da fundação do concreto (DTI, 2009).

As subpressões na fundação são forças verticais exercidas de baixo para cima sob a barragem. Ela é gerada pela água que percola através da fundação. Isto ocorre devido o gradiente hidráulico de montante e jusante da barragem. Villwock (2009) representa a resultante dessas forças como $F_{subpressão}$ e por $F_{reservatório}$ as forças horizontais (pressões hidrostáticas) que são aplicadas à barragem pelo reservatório estas duas são forças desestabilizadora. A força peso P da barragem é a estabilizadora. O balanceamento dessas forças pode causar tombamento e/ou deslizamento da barragem como é ilustrado na Figura 2.3.

FIGURA 2.3 - CONDIÇÕES DE CARGAS BÁSICAS E FORMAS DE INSTABILIDADE DE BARRAGENS DE GRAVIDADE DE CONCRETO




FONTE: Villwock (2009).

As medições de subpressões, observadas na fundação da barragem, são imprescindíveis para a análise das condições de estabilidade, já que através delas é possível determinar o nível freático e sua variação devido às chuvas e estiagens. O piezômetro é o instrumento que fornece a informação da subpressão.

A atenção nesta pesquisa se dará ao piezômetro *standpipe*. O equipamento em questão possui robustez e confiabilidade em relação aos dados de subpressão. A Figura 2.4 a seguir ilustra o referido instrumento.

FIGURA 2.4 - PIEZÔMETRO STANDPIPE



FONTE: Daniel (2004).

O piezômetro *standpipe* é composto por um tubo de PVC perfurado no trecho final, região onde é feito o bulbo. O bulbo é preenchido com areia de granulometria apropriada e envolvido com material geotextil, que é dependente do solo ou material circunvizinho. Acima do filtro veda-se a área com bentonita e logo após uma mistura de solo-cimento.

O registro do nível da coluna d'água no interior do tubo piezométrico é realizado através de um “pio elétrico”. Trata-se de um fio graduado ligado a um sensor que produz sinal sonoro quando em contato com a água. A medida feita em campo é a distância entre a cota de boca do instrumento e a cota do nível da água contida em seu interior. A partir desta informação é possível definir a subpressão no local (SILVEIRA, 2003).

Em suma o funcionamento do piezômetro *standpipe* ocorre da seguinte forma: a água passa através do filtro do bulbo drenante do instrumento até o elemento sensível do instrumento, ocasionando um fluxo d'água para dentro ou para fora deste, até que atinja o equilíbrio com a poropressão na fundação. A poropressão é representada, pela a altura da água acima do bulbo do instrumento.

A cota do nível de água (Cna) e a pressão no bulbo (PB) dos piezômetros são calculados pelas equações (2.1) e (2.2), respectivamente,

$$Cna = CB - Dbn \times \cos \alpha \quad (2.1)$$

$$PB = (Cna - CB) \times \gamma_a \quad (2.2)$$

onde γ_a é o peso específico da água; Dbn a diferença entre a boca do piezômetro e a posição do nível de água em seu interior; CB é a cota da boca do piezômetro e α o ângulo de inclinação do piezômetro com a vertical.

Medidas preventivas ou corretivas são implantadas partir do momento em que algum comportamento atípico das leituras é observado e se perpetua por um período tempo. Caso esse comportamento pudesse ser previsto, essas ações seriam antecipadas, proporcionando ainda mais a estabilidade e a saúde estrutural da barragem, tornando uma motivação para este estudo.

3 REVISÃO DA LITERATURA

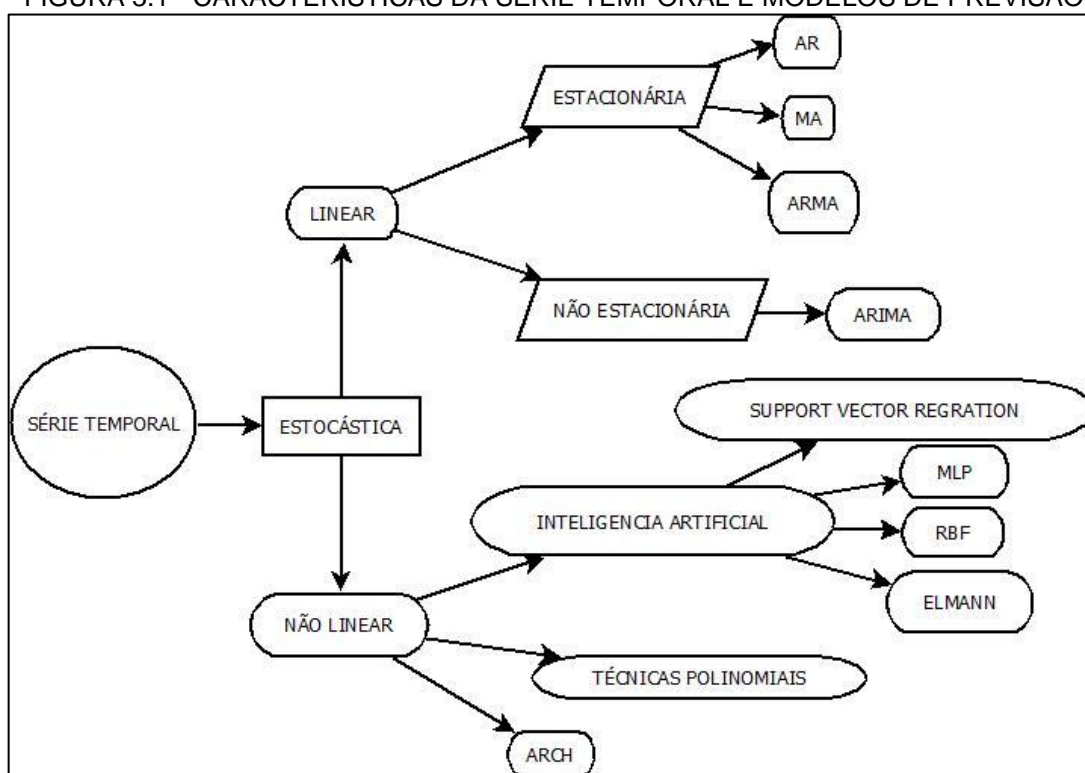
A partir da descrição do problema, define-se que o objeto de estudo é a série temporal formada pelas leituras do instrumento piezômetro. A previsão de séries temporais é um assunto pesquisado tanto na área de Estatística, em Inteligência Artificial e em muitas outras. Apresenta-se neste capítulo métodos de previsão de séries temporais.

3.1 PANORAMA GERAL DE MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS

A análise e estudo sobre de séries temporais tem como um de seus objetivos, a partir de suas características, identificar um método de previsão apropriado. A Figura 3.1, expõe algumas características que são consideradas para detectar um provável modelo de previsão. Portanto uma série temporal que possui uma correlação de dependência não linear é possivelmente melhor modelada por métodos de Inteligência Artificial (IA), Rede Neural Artificial, técnicas polinomiais ou ARCH (*Autoregressive Conditional Heterocedasticity*). Os métodos *Support Vector Regression*, Rede Neural Artificial *Multilayer Perceptrons* (RNA-MLP), Rede Neural Artificial de Funções de Bases Radiais (RNA-RBF) e Redes de Elmann também podem ser investigados.

Uma série que possui características lineares e estacionariedade, pode ser ajustada ao modelo Autorregressivo (AR), Médias Móveis (MA) ou Autorregressivo Médias Móveis (ARMA). Caso a série não seja estacionária o modelo Autorregressivo Integrado Médias Móveis (ARIMA) é aplicado.

FIGURA 3.1 - CARACTERÍSTICAS DA SÉRIE TEMPORAL E MODELOS DE PREVISÃO




FONTE: Modificado Scarpin (2012).

A série temporal do piezômetro PS-F-72 da Usina Hidrelétrica de Itaipu, por ser uma série real possui tanto características lineares como não lineares, sendo assim a utilização de modelos isolados pode não resultar em previsões assertivas.

A metodologia proposta é baseada em métodos híbridos de previsão de séries temporais. Este tema foi pesquisado na base *Web of Science*, especificando também a busca do modelo ARIMA e de Redes Neurais Artificiais.

Nota-se que a quantidade de publicações relacionadas a métodos híbridos de previsão de séries temporais, Figura 3.2, vem crescendo considerando os anos iniciais de sua proposta, partindo de três artigos em 1996, Voort et al. (1996), Ansuji et al (1996) e Wedding e Cios (1996). Em 2014 alcança o máximo de 27 artigos publicados e no ano de 2015, 19 publicações. O surgimento de modelagem utilizando RNA e algoritmos de identificação dos parâmetros para os modelos existentes é um dos agentes desse crescimento de metodologias híbridas.


FIGURA 3.2 - NÚMERO DE PUBLICAÇÕES POR ANO



FONTE: A autora (2016).

As dez revistas que mais publicam sobre este assunto estão dispostas na Figura 3.3, sendo que a revista *Expert Systems With Applications* possui classificação A2 em relação a Qualis Capes 2014, seguida pela *Neurocomputing* com a mesma classificação, cuja quantidade de publicações empata com a revista *Plos One* com Qualis A1.

FIGURA 3.3 - NÚMERO DE PUBLICAÇÕES POR REVISTA




FONTE: A autora (2016).

A Figura 3.4 expõe os trabalhos relacionados a métodos de previsão de séries temporais híbridos mais citados durante o período de tempo considerado.

Zhang (2003) possui a maior área do gráfico, significando ser o artigo mais citado. Este artigo é um dos trabalhos base desse estudo.

FIGURA 3.4 - DISTRIBUIÇÃO TEMPORAL DE CITAÇÕES.



FONTE: A autora (2016).

Zhang (2003) propôs um modelo híbrido que é a soma do modelo linear da série (ARIMA) e não linear do resíduo da modelagem ARIMA, modelado por meio de RNA-MLP. Detalhes dessa metodologia será abordada a seguir.

Os artigos de Pai e Lin (2006) e Rojas *et al.* (2008) também possuem uma distribuição temporal de citações significativa em relação aos demais, embora o artigo de Zhang (2003) seja mais expressivo neste sentido.

3.2 TRANSFORMAÇÕES WAVELET APLICADA A SÉRIES TEMPORAIS

A transformação dos dados de uma série temporal geralmente é realizada com o fim de melhorar o ajuste do modelo de previsão e consequentemente sua precisão. Pode-se citar as seguintes transformações: a Decomposição *Wavelet* (DW) realizada por Adamowski e Chan (2011), Teixeira Jr (2013), Seo et al. (2015), Caswell (2014); *Empirical mode decomposition* (EMD); Transformada de Fourier

(TF); Representação Volterra, Maheswaran e Khosa (2015); Suavização Binomial, Zheng e Zhong (2011); entre outras.

A técnica de origem matemática, transformada ou Decomposição *Wavelet*, é considerada uma forma adequada de processamento de dados. A DW está sendo aplicada em análise de dados de séries temporais, pois este método é capaz de lidar com séries temporais não estacionárias (ADAMOWSKI; CHAN, 2011 e CHAOVALIT et al., 2011).

A série temporal original é decomposta em diferentes componentes, uma de aproximação, de alta frequência, que mantém a tendência geral da série, n componentes de detalhe que contêm componentes de alta frequência e são separadas em diferentes frequências e escalas (SEO et al., 2015). A DW supera a limitação da TF (ADAMOWSKI; CHAN 2011).

De acordo com Soltani (2002), a DW resulta em novas séries hierárquicas que são mais "fáceis" de modelar e de fazer a previsão. O autor afirma que a série de aproximação possui pouco ruído, enquanto que a série de detalhe de mais baixa ordem é mais suscetível a ruído.

Soltani (2002) utiliza a decomposição *Wavelet* de nível três, modela separadamente as séries geradas pela decomposição, embora considere o mesmo tamanho do padrão de entrada para as RNA-MLP utilizadas. A previsão final é a soma das previsões de cada componente. A modelagem feita por ele utiliza variáveis exógenas, ou seja, o padrão é composto pela mistura de componentes da série de aproximação e de detalhes. O autor conclui que a utilização da DW provê uma melhora na previsão comparado a métodos como *Time Delay Neural Network* (TDNN) e RNA.

A Decomposição *Wavelet* de nível dois, integrado ao modelo AR(p), foi utilizado por Mabrouk et al. (2008). As componentes de decomposição são modeladas separadamente pelo modelo AR e depois somadas. A previsão é realizada um passo a frente, n vezes, ou seja, é previsto um valor e este é utilizado para fazer a próxima previsão, isso ocorre até que o horizonte de tempo n definido seja alcançado. Os autores constataram uma melhoria em relação aos erros de previsão a partir da metodologia proposta em relação ao trabalho de Soltani (2002) e outros trabalhos que constam na pesquisa.

Kisi; Cimen (2011) fazem a DW de nível três da série temporal estudada, empregando os filtros passa alta e passa baixa proposta por Mallat (1989), em

relação a bases ortonormais. O dado de entrada ao método *Support Vector Regression* (SVR) é a soma da componente de aproximação e a componente de detalhe que tem maior correlação com a série original. O método proposto atinge resultados de previsão melhores do que o SVR utilizado sem a decomposição.

Adamowski; Chan (2011) utilizam os filtros passa alta e passa faixa, sendo que os coeficientes de detalhe e aproximação são obtidos por meio do algoritmo *Wavelet*. A filtragem dos dados é realizada quando uma porção da série de determinada frequência é eliminada da decomposição. As séries geradas são somadas e utilizadas como entrada na RNA-MLP.

O pré-processamento da série de dados é realizado através da transformada *multiwavelet*, no trabalho de Liu et al. (2011), a fim de se obter mais características da série. Os resultados dessa transformação foram utilizados como padrão de entrada para a RNA-MLP, RNA-RBF e a RNA *Wavelet*. A combinação desses métodos foi realizada por meio da RNA MLP. A precisão alcançada por este método é maior do que as redes utilizadas separadamente e também pela combinação das redes sem a aplicação da transformação *multiwavelet*.

Na investigação realizada por Teixeira Jr (2013) as componentes *Wavelets* da série temporal são utilizadas como padrões de entrada da RNA-MLP, enquanto que os padrões de saída são os dados originais da série temporal. Esta modificação gerou um ganho preditivo se comparado à rede cujos padrões de entrada eram compostos pelos dados originais da série.

Caswell (2014) aplica a Decomposição *Wavelet* a série temporal e a integra a RNA-MLP e a Regressão Linear. A melhoria da previsão utilizando a decomposição é revelada por meio da comparação desses métodos incorporando ou não a decomposição *Wavelet*.

A combinação da transformada *Wavelet* discreta de sobreposição máxima e o modelo ARMA foi realizada por Zhu et al. (2014). O objetivo era tratar séries temporais não estacionárias e de dependência de longa duração. Os autores mostraram que as séries de detalhe obtidas pela decomposição são estacionárias e de dependência de curta duração. Cada componente *Wavelet* é modelada e prevista pelo modelo ARIMA. A previsão da série é dada pela soma das previsões das componentes. Averiguou-se um ganho na precisão do modelo proposto em relação ao modelo ARIMA e em relação a outras variações do modelo utilizando outros tipos de decomposições.

Dois métodos híbridos baseados em decomposição *Wavelet* foram propostos por Seo et al. (2015) para previsão de séries temporais que possuem estrutura de autodependência não lineares. O primeiro método utiliza RNA-MLP e o segundo um sistema de inferência neuro-*fuzzy* adaptativo. As séries decompostas são utilizadas como dados de entrada nos métodos citados, ocasionando uma melhora na capacidade de previsão dos métodos em relação a não decomposição dos dados da série temporal. Os autores observaram que os dados de entrada influenciam no desempenho da previsão, consequentemente o conjunto de *Wavelets* também geram alterações no resultado das previsões.

A escolha da *Wavelet* tem impacto na transformação dos dados, uma das mais utilizadas é a *Wavelet* Daubechies.

3.3 MÉTODOS DE PREVISÃO

A previsão de séries temporais por meio de metodologias híbridas, ou seja, compostos por modelos lineares e não lineares, é o foco da metodologia desenvolvida. Há, porém, na literatura trabalhos que utilizam métodos estatísticos vinculados a RNA ou métodos de inteligência artificial acoplado a modelos estatísticos de previsão, para definir parâmetros do modelo em questão. São apresentados alguns trabalhos referentes a esse tipo de abordagem na sequência.

3.3.1 Métodos acoplados a modelos de previsão de séries temporais

Visto que a definição de parâmetros dos modelos de previsão de séries temporais não é uma tarefa trivial, tanto para modelos de IA quanto para modelos estatístico, técnicas e procedimentos foram desenvolvidos para este fim.

Valenzuela et al. (2008) desenvolveram um sistema especialista *fuzzy*, que foi otimizado a partir do algoritmo evolutivo, com o fim de definir automaticamente o modelo ARIMA correto. Alguns *softwares* comerciais possuem a opção de previsão automática de séries temporais, mas estes, em geral não são bem sucedidos. É

necessário, mesmo assim, a interferência dos usuários no *software* para definir o modelo, ou seja, a experiência do pesquisador é imprescindível para a modelagem.

Lee et al. (2009) aplicam o critério do *M*-estimador de *Welsch* para o ajuste dos parâmetros e o operador mediano para estimar a escala do espalhamento de cada centróide na RNA-RBF. A análise de significância do neurônio na camada oculta foi empregada para definir a quantidade de neurônios na camada oculta. As modificações promoveram a diminuição do erro de previsão, mesmo quando adicionado um ruído de 30% aos dados iniciais.

Uma das características da pesquisa de Liao (2010) é a utilização do algoritmo híbrido nomeado de *Genetic k-Means Algorithm* (GKMA), algoritmo *k*-médias genético. O objetivo da utilização desse método era evitar a convergência a mínimos locais e diminuir a sensibilidade das escolhas aleatórias iniciais dos centróides da RNA-RBF. A seleção apropriada do conjunto de centros dentre os dados de entrada foi definida pelo algoritmo de aprendizagem Orthogonal Least Squares (OLS). As larguras das RBFs são estabelecidas pela heurística do vizinho mais próximo. A técnica alcançou êxito para a previsão do ponto de potência em painéis fotovoltaicos.

Herrera et al. (2011), afirmam que a múltipla influência do centro da RBF ao padrão de entrada deve ser eliminada, pois o dado de entrada deve ser dominado por um respectivo centro na função global de saída do sistema. Para tanto é aplicado um sistema *fuzzy* para o agrupamento dos padrões de entrada, fundamentado na fixação de centros antecedentes. A posição relativa de cada neurônio é associada aos demais. O erro dos mínimos quadrados é utilizado para fazer a otimização dos coeficientes lineares *neuro-fuzzy* e a decomposição de valores singulares para obter os valores das equações lineares. Experimentos com séries temporais revelaram que é possível atingir um comportamento global adequado, juntamente com componentes de modelos locais no espaço dos padrões de entrada ao redor das funções de bases radiais.

Coelho; Santos (2011) estimam os parâmetros de seu modelo de previsão por meio da função de máxima verossimilhança. Para maximizar esta função é aplicado o *Genetic Algorithm* (GA). A utilização do GA proporciona uma busca estocástica eficiente ao longo do espaço de parâmetros, diminuindo a possibilidade da solução candidata representar um mínimo local.

O algoritmo de aprendizagem composto por duas etapas é proposto por Lin e Wu (2011), sendo esta supervisionada e não supervisionada. A primeira etapa analisa a relação dos dados de entrada por meio da rede SOM, a partir disso estabelece-se o relacionamento e a distribuição dos dados no espaço de entrada. Denotados por pesos sinápticos, a distribuição dos dados de entrada, são potenciais neurônios na camada escondida da RBF. A verificação da utilização ou não dos pesos é realizada na segunda etapa do aprendizado. O objetivo do método é ajudar na identificação da configuração ótima da rede RBF.

Wu et al. (2012) fazem a combinação linear de vários tipos de funções de bases radiais, a fim de melhorar a capacidade de generalização da RNA-RBF. Esta técnica é aplicada para fazer a previsão da sensibilidade de reservatórios e para isso utiliza dados correlacionados a esta informação.

A seleção automática das variáveis adequadas de entrada, o número de neurônios na camada escondida e a otimização dos parâmetros da RNA-RBF são realizadas simultaneamente pelo modelo híbrido proposto por Gan et al. (2012). A proposta dos autores é composta pelo GA para definição da quantidade de informações dos padrões de entrada e de neurônios da camada oculta; e o método de otimização de estruturas de parâmetros não lineares, para calcular os centros, as larguras da RBF e pesos; a função de aptidão utilizada foi o MSE. A aplicação do método gerou melhores resultados, comparado a outros trabalhos, em relação ao conjunto de teste das séries, além de diminuir a quantidade de parâmetros das redes.

O algoritmo evolucionário vinculado com método de otimização de parâmetros de estrutura não linear são aplicados por Gan et al. (2012) a fim de identificar os parâmetros do modelo da RNA-RBF e dos modelos híbridos. RBF-AR (RNA-RBF integrado ao autorregressivo) e RBF-AR(X) (RNA-RBF integrado ao autorregressivo com variável exógena).

Mínimos quadrados ortogonais e GA são empregados por Chang (2013) para diminuir o tamanho da rede neural RBF. Esses métodos são aplicados na fase de treino. O primeiro método citado determina a quantidade de centroides e o segundo para a definição dos centros, as larguras das RBF e os pesos da rede. O método obteve uma maior exatidão na previsão de energia eólica se comparada a métodos que são usualmente empregados para este fim.

O agrupamento *fuzzy* é aplicado por Tsekouras (2013) em sua pesquisa, isso é feito a partir de dois enfoques: nos dados de entrada e nos dados de entrada e saída. A justificativa está no fato de que, ao se considerar apenas os dados de entrada para o agrupamento, a estrutura dos dados de saída são desprezados no processo de aprendizagem. Considerando tanto os dados de entrada quanto os de saída da rede os centros das funções de bases radiais da RNA-RBF sofrem influência desses dois parâmetros. O algoritmo *Particle Swarm Optimization* (PSO) é utilizado para determinar os centroides dos agrupamentos da RBF.

3.3.2 Modelos híbridos de previsão de séries temporais

Define-se como modelo híbrido de previsão, aqueles compostos por modelos estatísticos e de IA.

Pai e Lin (2005) associam a modelagem linear ARIMA e a não linear *Support Vector Machine* (SVM) a fim de captar a estrutura de autodependência de série de dados de preços de ações. Primeiramente é realizada a modelagem ARIMA da série e depois seus resíduos são aplicados ao SVM. A previsão um passo a frente desses modelos são somados gerando a previsão final.

A soma linear das previsões ARIMA com as previsões dos resíduos da série modelados por RNA é utilizada por Valenzuela et al. (2008), alegam que a aplicação do método ARIMA permite remover a característica linear da série. A linearidade, para os autores, é capaz de diminuir a eficácia da RNA se aplicada diretamente. Portanto, ao se extrair a característica de autodependência linear por meio do modelo ARIMA é possível diminuir a quantidade de parâmetros, a complexidade, o risco de *overfitting* e melhorar a previsão obtida pela RNA-MLP. Foram testadas várias séries temporais da literatura e obteve-se excelentes resultados.

A identificação da estrutura ARIMA é realizada por um sistema *Fuzzy* proposto Rojas et al. (2008), com o objetivo de aumentar a precisão do modelo híbrido de previsão. A metodologia híbrida tem as mesmas características da apresentada por Valenzuela et al. (2008).

Coelho e Santos (2011) apresentam um modelo de previsão não linear baseado na RNA-RBF e GARCH. A metodologia tem como finalidade fornecer a

previsão de um ponto n passos à frente, além de indicar a direção de mudança de previsões da série temporal do preço da eletricidade espanhola. A abordagem aplicada superou modelos lineares tradicionais e experimentos mostraram que previsões com um horizonte de tempo maior também obtiveram bons resultados, principalmente para a movimentação dos preços futuros.

A RNA-RBF combinada com o modelo autorregressivo (AR) e o pré-processamento dos dados por meio de suavização binomial foram aplicados por Zheng e Zhong (2011). Este modelo foi nomeado como BS-RBFAR. Os resultados experimentais apontam que o problema de *overfitting* poder ser diminuído ao se empregar a RNA-RBF embasada na suavização exponencial. Este modelo híbrido proposto é uma forma eficiente de melhorar a exatidão das previsões comparativamente a apenas fazer a suavização e aplica-la a RNA-RBF. A previsão realizada pelos autores é um passo a frente.

O fluxo de passageiros da linha de metro de Pequim foi prevista por Jiurian e Bingfeng (2013) por meio de um modelo híbrido composto por ARIMA e RNA-RBF, aplicados nesta ordem. A RBF é aplicada aos resíduos do método ARIMA; a previsão final é a soma dos ajustes; obteve-se também um bom desempenho comparado à utilização dos modelos separadamente.

O modelo MA é empregado por Babu e Reddy (2014) como um filtro linear da série, gerando uma série denominada de tendência e a série de resíduos. A série de tendência é modelada pelo método ARIMA e os resíduos por meio da RNA-MLP. A previsão final (um passo a frente ou n passos a frente) é obtida por meio da soma das previsões do método ARIMA e da RNA-MLP. A série das Manchas Solares é uma das séries utilizadas pelos autores e a comparação do método proposto nesta tese não pode ser comparada com este trabalho, pelo fato do horizonte de previsão aplicados por eles ser diferente.

Adhikari e Agrawal (2014) propõem uma metodologia híbrida composta pelos métodos: ARIMA, *Support Vector Machines* (SVM), RNA-MLP, RNA Elman iterativa e RNA Elman direta. A série é aplicada a cada uma das técnicas, a combinação dessas técnicas é realizada pela média e mediana das previsões em relação a cada instante t e do erro aleatório.

3.4 TRABALHOS CORRELATOS RELACIONADOS A METODOLOGIA PROPOSTA

Os trabalhos da literatura que embasam as metodologias propostas são apresentados nesta seção. Essas metodologias geram o ajuste um passo a frente.

O ajuste um passo a frente utilizam os dados anteriores da série para prever o próximo valor. A previsão um passo a frente e n passos a frente (*multi-step*), faz a substituição dos valores pelos previstos, a fim de realizar a previsão do conjunto de teste.

Zhang (2003) propôs uma metodologia híbrida composta da modelagem da serie temporal original por meio do ARIMA e os resíduos deste modelo foram aplicados a RNA-MLP. As séries empregadas pelo autor, o conjunto de treino e de teste são expostos no Quadro 3.1.

QUADRO 3.1 - COMPOSIÇÃO DAS AMOSTRAS EM TRÊS CONJUNTOS DE DADOS

SERIES	TAMANHO		
	AMOSTRA	CONJUNTO DE TREINO	CONJUNTO DE TESTE
LINCES CANADENSES	1821 - 1934 (114)	1821 - 1920 (100)	1921 - 1934 (14)
MANCHAS SOLARES WOLF	1700 - 1987 (288)	1700 - 1920 (221)	1921 - 1987 (67)
TAXA DE CÂMBIO	1980 - 1993 (731)	1980 - 1992 (679)	1993 (52)

FONTE: Modificado Zhang (2003).

A especificação da série e dos conjuntos de treinamento e de teste são adotados neste estudo conforme o apresentado no Quadro 3.1, além da suavização que é realizada pelo autor. Nas séries temporais dos Linces Canadenses e da Taxa de câmbio é aplicado o logaritmo aos dados.

Zhang (2003) propõe que a previsão um passo a frente da série temporal é composta de acordo com a equação (3.1).

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (3.1)$$

onde \hat{L}_t é a previsão realizada pelo método ARIMA e \hat{N}_t a previsão do resíduo obtido por meio da RNA-MLP. Os resíduos são utilizados para verificar a adequação

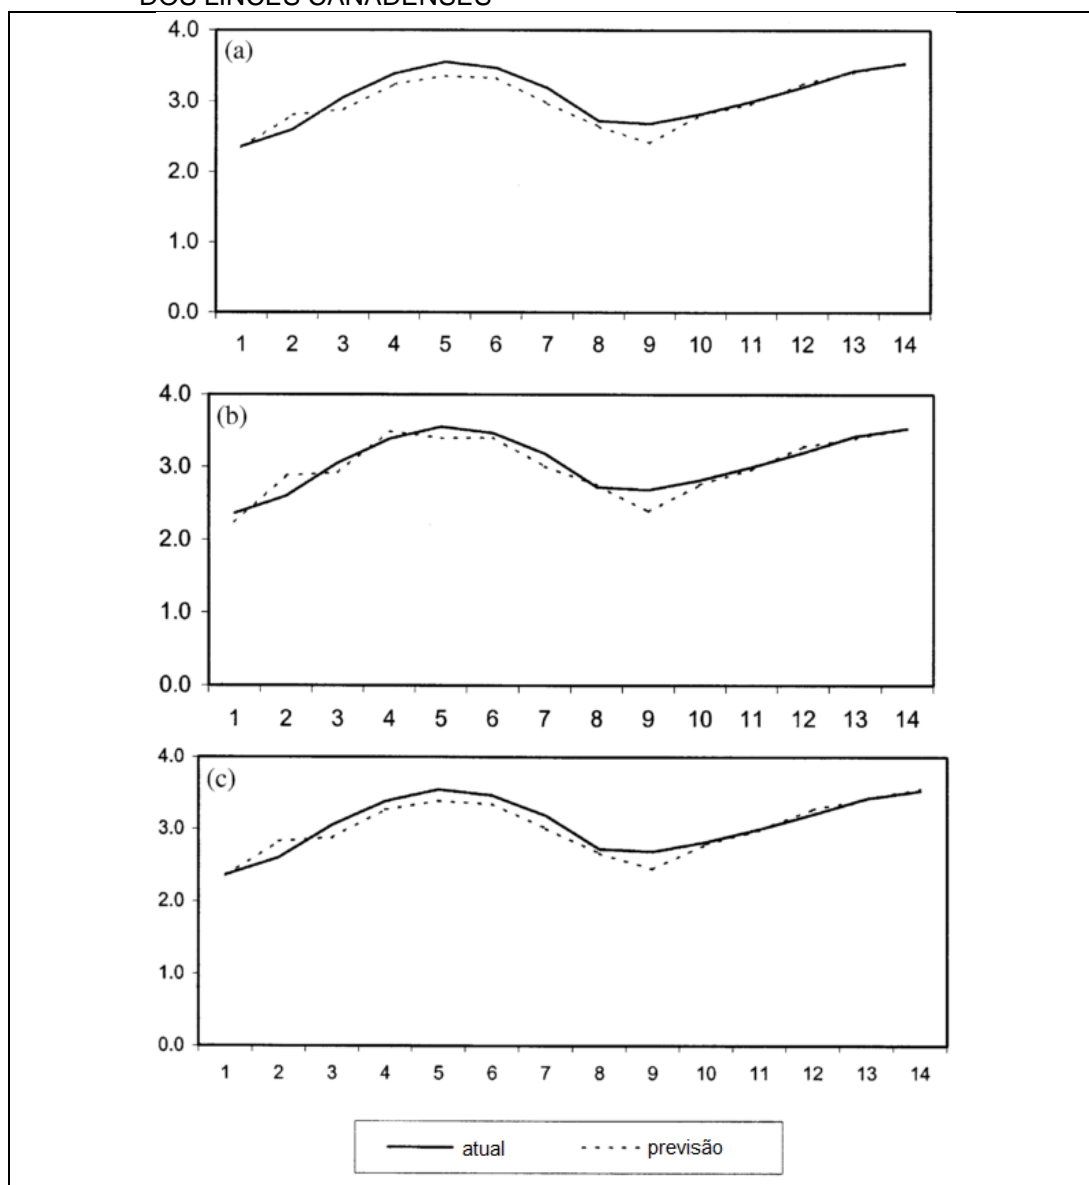
do modelo, mas a análise dos resíduos não informam se existe ainda autocorrelação não linear entre eles. Segundo o autor, por esta razão é realizada a modelagem dos resíduos por meio de um método não linear de previsão, RNA-MLP.

As previsões obtidas por Zhang em relação a cada série em questão são apresentadas na Figura 3.5, Figura 3.6 e Figura 3.7.

Os gráficos apresentados por Zhang (2003) não possuem indicação dos eixos, mas pode-se inferir que o eixo dos y , são o logaritmo da quantidade de Lince canadenses capturados, o eixo dos x , os anos. A modelagem da autocorrelação linear da série dos Lince canadenses é realizada a partir do modelo AR(12), apresentado na Figura 3.5 (a) para o conjunto de teste. Seu resíduo é aplicado a RNA-MLP, não é informada a estrutura da rede aplicada aos resíduos, a fim de ser somado ao resultado do modelo AR(12), gerando o modelo híbrido (c) de Zhang.

A previsão um passo a frente é realizada com o objetivo de se verificar o aumento da precisão utilizando o modelo híbrido. A série também foi aplicada isoladamente ao método ARIMA e RNA-MLP. A rede é composta de 7 elementos no padrão de entrada, 5 neurônios na camada oculta e um neurônio de saída, a previsão da série pode ser observada na Figura 3.5 (b).

FIGURA 3.5 - PREVISÕES REALIZADAS POR ZHANG (2003) AO CONJUNTO TESTE DA SÉRIE DOS LINCES CANADENSES



FONTE: Adaptado Zhang (2003).


LEGENDA: (a) Previsão ARIMA.

(b) Previsão RNA-MLP.

(c) Previsão Híbrida Zhang (2003).

Embora não apontado pelo autor, interpreta-se que o eixo dos y é o número de Machas Solares e o eixo dos x refere-se ao ano. O modelo AR(9) é empregado à série das Manchas Solares e a previsão para o conjunto de teste é apresentado na Figura 3.6 (a). Os resíduos desse modelo são aplicados a RNA-MLP, a estrutura da rede não é indicada pelo autor. A soma das previsões citadas anteriormente gera a previsão híbrida que é exposta em (c).

FIGURA 3.6 - PREVISÕES REALIZADAS POR ZHANG (2003) AO CONJUNTO DE TESE DA SÉRIE DAS MANCHAS SOLARES



FONTE: Adaptado Zhang (2003).

LEGENDA: (a) Previsão ARIMA.

(b) Previsão RNA-MLP.


(c) Previsão Híbrida Zhang (2003).

A RNA-MLP composta de 4 elementos no padrão de entrada, 4 neurônios na camada oculta e um neurônio de saída é utilizada para fazer a previsão exibida em (b) da figura anterior.

Como os eixos não são identificados pelo autor na figura anterior, supõe-se então que o eixo dos y é o logaritmo da Taxa de Câmbio e o eixo dos x as semanas. O modelo *Random Walk* $y_t = y_{t-1} + \varepsilon_t$ é aplicado por Zhang (2003) à série da Taxa de Câmbio (a). A RNA-MLP teve a estrutura de 7 elementos na composição do padrão, 6 neurônios na camada oculta e 1 neurônio na camada de saída (b). A previsão híbrida, constituída pela soma da previsão do passeio aleatório e a previsão de seus

resíduos pela RNA-MLP é apresentado em (c) da Figura 3.7, ressaltando que a estrutura da rede aplicada aos resíduos não foi informada pelo autor.

FIGURA 3.7 - PREVISÕES REALIZADA POR ZHANG (2003) PARA A SÉRIE DA TAXA DE CÂMBIO



FONTE: Adaptado Zhang (2003).

LEGENDA: (a) Previsão ARIMA.

(b) Previsão RNA-MLP.

(c) Previsão Híbrida Zhang (2003).

Khashei e Bijari (2011) propõem um modelo híbrido composto por duas fases: primeiramente é aplicado o modelo ARIMA, com a finalidade de identificar a estrutura linear existente nos dados; a RNA-MLP é empregada na segunda fase, para captar a estrutura não linear, com o objetivo de modelar os resíduos do método anterior e os dados originais. As combinações dessas fases formam a previsão proposta, como definida na equação (3.2).

$$y_t = f(N_t^1, \hat{L}_t, N_t^2) \quad (3.2)$$

onde \hat{L}_t é a previsão do valor no tempo t , a previsão é realizada pelo modelo ARIMA; N_t^1 é o resíduo da previsão ARIMA, N_t^2 é o dado original da série ambos modelados pela RNA-MLP. Todas as modelagens são combinadas por meio de f , sendo essa a representação da RNA-MLP utilizada por Khashei e Bijari (2011).

A estrutura da RNA-MLP (f) empregada por Khashei e Bijari (2011) é especificada no QUADRO 3.2 para cada série estudada. As séries, os intervalos e as suavizações feitas nas séries são as mesmas apresentadas no trabalho de Zhang (2003).

A modelagem ARIMA para as séries temporais, a previsão um passo a frente também são as mesmas definidas por Zhang (2003).

QUADRO 3.2 - ESTRUTURA DA RNA-MLP UTILIZADA NO MODELO HÍBRIDO DE KHASHEI E BIJARI (2011)

SÉRIE	PADRÕES	NEURÔNIOS DA CAMADA OCULTA	NEURÔNIOS DA CAMADA DE SAÍDA
Linces Canadenses	$e_{t-1}, e_{t-2}, \hat{L}_t, z_{t-1}, z_{t-2}, z_{t-3}, z_{t-4}, z_{t-5}$	3	1
Manchas Solares	$e_{t-1}, e_{t-2}, \hat{L}_t, z_{t-1}, z_{t-2}, z_{t-3}, z_{t-4}$	3	1
Taxa de Câmbio	$e_{t-6}, e_{t-5}, e_{t-4}, e_{t-3}, e_{t-2}, e_{t-1}, \hat{L}_t, z_{t-1}, z_{t-2}, z_{t-3}, z_{t-4}, z_{t-5}$	4	1


FONTE: Modificado Khashei e Bijari (2011).

Os valores e denotam os erros da modelagem ARIMA, enquanto z representam os dados originais da série. A série dos Linces Canadenses possuem 8 nós de entrada, enquanto as Manchas Solares são compostas por 8 nós e a Taxa de Câmbio possui 12 nós na camada de entrada.

O resultado da metodologia proposta por Khashei e Bijari (2011), pode ser averiguada na Figura 3.8.

Os eixos de cada gráfico da Figura 3.8, não foram indicados pelos autores, entende-se que os eixos são definidos de acordo como foi descrito no trabalho de Zhang (2003).

FIGURA 3.8 - PREVISÃO DO MODELO PROPOSTO POR KHASHEI E BIJARI (2011) PARA O CONJUNTO DE TESTE



FONTE: Adaptado Khashei e Bijari (2011).

LEGENDA: (a) Série dos Linces Canadenses.
(b) Série das Manchas Solares.
(c) Série da Taxa de Câmbio.

A adequação das metodologias nesta seção são apresentadas no capítulo de resultados e discussões.

3.5 FUNDAMENTAÇÃO TEÓRICA

Nas subseções a seguir, são expostas a fundamentação teórica base para o desenvolvimento da nova metodologia híbrida. Iniciando com séries temporais que é o objeto de estudo e prosseguindo com as técnicas utilizadas para previsão de séries temporais e de decomposição da série temporal.

3.5.1 Séries temporais

A análise de séries temporais possui aplicação em várias áreas, pode-se citar como exemplo: financeira, hidrologia, médica, ciências sociais, redes de computadores e de negócios (CHANG, 2013, CHAOVALIT et al., 2011, LIAO, 2010, SEO et al., 2015 e TSEKOURAS, 2013).

De acordo com Box et al. (2008), uma série temporal consiste em uma coleção de observações correlacionadas sequencialmente no tempo (contínuo ou discreto), sendo o intervalo de tempo fixo; o mecanismo gerador da série é um processo estocástico. Denota-se por série temporal: $y_t(t = 1, \dots, T)$.

A avaliação da dependência entre as observações, a construção de modelo e a previsão da série temporal são algumas das finalidades da análise de séries temporais. Para que a previsão da série temporal seja realizada é necessária a elaboração de um modelo que descreva a série histórica da variável em questão, sendo que este é extrapolado para valores futuros (KHASHEI; BIJARI, 2011).

Denota-se por série temporal estacionária, quando expande-se aleatoriamente ao redor de uma média e variância constantes. A escolha da origem da série em relação ao tempo não é importante se esta for estacionária. Entretanto a maioria das séries de aplicações reais não apresenta estacionariedade. Geralmente estas possuem tendências lineares ou então não-estacionariedade explosiva, um exemplo desta última é o crescimento de uma colônia de bactérias. (MORETTIN; TOLOI, 2006).

O início da análise da série temporal se dá por meio do cálculo das funções: de autocovariância (γ_k), de autocorrelação (ρ_k) e autocorrelação parcial (ϕ_{kk}), Box et al. (2008).

- Função de autocovariância (FACV), avalia quanto o valor atual da amplitude da série depende de seus valores passados, é estimada pela estatística apresentada na equação (3.3).

$$\hat{\gamma}_k = \frac{1}{n} \sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y}) \quad (3.3)$$

onde a média é representada por $\bar{y} = \frac{1}{n} \sum_{t=1}^n y_t$, sendo que n é o número de observações da série;

- Função de autocorrelação (FAC), estimada pela equação (3.4), cuja representação gráfica o correlograma, provê informações sobre a possível estrutura do modelo:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (3.4)$$

sendo γ_0 a variância da série temporal;

- Função de autocorrelação parcial (FACP), é estimada pela solução do sistema composto pelas equações de Yule-Walker, representada pelo conjunto de equações (3.5), cujo gráfico, correlograma integrado, também auxilia na identificação da estrutura do modelo.

$$\begin{cases} \hat{\rho}_1 = \hat{\phi}_{k1}\hat{\rho}_0 + \hat{\phi}_{k2}\hat{\rho}_1 + \cdots + \hat{\phi}_{k(k-1)}\hat{\rho}_{k-2} + \hat{\phi}_{kk}\hat{\rho}_{k-1} \\ \hat{\rho}_2 = \hat{\phi}_{k1}\hat{\rho}_1 + \hat{\phi}_{k1}\hat{\rho}_0 + \cdots + \hat{\phi}_{k(k-1)}\hat{\rho}_{k-3} + \hat{\phi}_{kk}\hat{\rho}_{k-1} \\ \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \\ \hat{\rho}_k = \hat{\phi}_{k1}\hat{\rho}_{k-1} + \hat{\phi}_{k2}\hat{\rho}_{k-2} + \cdots + \hat{\phi}_{k(k-1)}\hat{\rho}_1 + \hat{\phi}_{kk}\hat{\rho}_0 \end{cases} \quad (3.5)$$

Os coeficientes de autocorrelação parcial medem a relação entre y_t e y_{t+k} , ou seja entre as observações da série temporal.

O Quadro 3.3 exhibe algumas das séries que são geralmente estudadas no âmbito de previsão de séries temporais. Observa-se que muitos trabalhos são publicados na área de hidrologia, sendo as séries temporais dessa área de difícil modelagem e previsão, geralmente consideradas não estacionárias.

QUADRO 3.3 - TIPOS DE SÉRIES ESTUDADAS NA LITERATURA

Séries	Autores
Mackey-Glass	Soltani (2002); Valenzuela et al. (2008); Mabrouk et al. (2008); Lee et al. (2009); Zhu et al. (2014); Gan, Peng e Dong (2012); Gan, Peng e Chen (2012)
Energia Eólica	Chang (2013)
Atividade de raios cósmicos	Caswell (2014)
Séries da área de hidrologia	Teixeira Jr (2013); Zhu et al (2014); Seo et al (2015), Adamowki e Chan (2011); Kisi e Cimem (2011); Valenzuela et al. (2008), Wu et al. (2012)
Manchas solares	Zhang (2003), Mabrouk et al. (2008); Khashei e Bijari (2011); Soltani (2002), Valenzuela et al (2008); Gan et al. (2012), Adhikari; Agrawal (2014), Babu; Reddy (2014)
Preço da eletricidade	Coelho e Santos (2011), Babu; Reddy (2014)
Série senos	Herrera et al (2011); Lee et al (2009)
Ponto de potência em painéis fotovoltaicos	Liao (2010)
Ciclo de consumo de combustível	Tsekouras (2013)
Preço de ações da empresa Larsen e Toubro na bolsa de Nova Iorque	Babu; Reddy (2014)
Valores de habitações	Tsekouras (2013)
Séries de dados gerados aleatoriamente	Tsekouras (2013)
Vírus da Hepatite A	Ture e Kurt (2006)
Produção australiana mensal de eletricidade	Valenzuela et al (2008)
Número de usuários conectados a um servidor de Internet	Valenzuela et al (2008)
Carga de energia	Liu, Li, Sun (2011)
Linces canadenses	Zhang (2003), Aladag et al. (2009) Zheng e Zhong (2011), Khashei; Bijari (2011), Adhikari; Agrawal (2014)
Fluxo de água em reservatório	Lin, Wu (2011)
Taxa de Câmbio da libra esterlina e o dólar americano	Zhang (2003), Khashei; Bijari (2011)

FONTE: A autora (2016)

3.5.2 Método ARIMA

O método Autorregressivo Integrado Médias Móveis (ARIMA) foi elaborado por Box e Jenkins em 1970 para prever séries temporais. Valenzuela et al. (2008)

afirmam que para aplicação deste é necessária a suposição de que as variáveis tenham uma relação de autodependência linear.

Khashei e Bijari (2011) informam que o método ARIMA é um dos mais consagrados modelos lineares, para previsão de séries temporais. Este é largamente adotado em modelos híbridos com o objetivo de elevar a capacidade de predição, pode-se verificar essa afirmação pela quantidade de trabalhos expostos na seção 3.3.2.

Os estágios da metodologia Box e Jenkins compreendem: a identificação, a estimação e a verificação da adequação do modelo.

Os modelos lineares empregados a série temporal estacionárias são:

- Autorregressivos de ordem (p), denotado por $AR(p)$, representado pelas equações (3.6) e (3.7), respectivamente;

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + a_t \quad (3.6)$$

$$\phi(B) y_t = a_t \quad (3.7)$$

onde $\phi(B) = 1 - \sum_{i=1}^p \phi_i B^i$, sendo B o operador de translação para o passado definido

como $By_t = y_{t-1}$, $B^m y_t = y_{t-m}$ e a_t o ruído aleatório assumido independente e identicamente distribuído com média zero e variância constante σ^2 .

- Médias Móveis de ordem (q), denotado por $MA(q)$, definido pelas equações (3.8) e (3.9);

$$y_t = \delta + a_t - \theta_1 a_{t-1} + \theta_2 a_{t-2} + \cdots + \theta_q a_{t-q} \quad (3.8)$$

$$y_t = \delta + \theta(B) a_t \quad (3.9)$$

onde $\theta(B) = 1 - \sum_{j=1}^q \theta_j B^j$.

$\phi_i (i = 1, 2, \dots, p)$ e $\theta_j (j = 1, 2, \dots, q)$ são os parâmetros do modelo.

- Modelos mistos ARMA (p, q), equação (3.10).

$$\phi(B) y_t = \delta + \theta(B) a_t \quad (3.10)$$

A indicação da estrutura do modelo AR é proveniente da FACP, enquanto o modelo MA é especificado pela FAC.

A condição de estacionariedade para o modelo $AR(p)$ é que as raízes de $\phi(B)$ estejam fora do círculo unitário, ou seja $|B| > 1$, a condição de invertibilidade do modelo $MA(q)$ é que as raízes de $\theta(B)$ estejam fora do círculo unitário.

Uma série temporal não estacionária pode ser representada pelo Modelo Autorregressivo Integrado Médias Móveis de ordem (p,d,q) , denotado por $ARIMA(p,d,q)$, equação (3.11), a diferenciação da série é realizada para se alcançar a estacionariedade na média.

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (3.11)$$

onde d é o grau de diferenciação da série e $\nabla^d = (1-B)^d$ o operador de diferenciação.

A formulação apresentada está conforme o livro de Morettin; Toloi (2006) e Box et al. (2008).

3.5.3 Redes Neurais Artificiais.

Esta metodologia se enquadra à necessidade de modelar séries temporais não lineares complexas e sistemas dinâmicos, sendo efetivamente empregada em estudos como: Zhang (2003), Ture e Kurt (2006), Khashei e Bijari (2011); Coelho e Santos (2011) dentre outros. A sua principal vantagem segundo Valenzuela et al. (2008), é a propriedade de aproximação universal, e também seus parâmetros são ajustados iterativamente e otimizados através de aprendizagem dos padrões históricos.

A RNA é considerada por Khashei e Bijari (2011) um dos mais importantes modelos de séries temporais não lineares e não paramétricos. Os autores listam seus benefícios como: capacidade de aproximar qualquer função mensurável continua com uma precisão arbitraria; imposição de poucas suposições para a sua aplicação; capacidade de generalização mesmo sendo aplicados em meios não estacionários e por fim utilizam menos parâmetros se comparado a outros métodos.

Em algumas ocasiões específicas em que a RNA possui um desempenho inferior aos modelos lineares estatísticos, é justificado no trabalho de Khashei e

Bijari (2011) e por outros pesquisadores pelo fato dos dados apresentarem relações lineares e não terem perturbações. A quantidade pequena de nós na camada escondida de uma *Multilayer Perceptrons* (MLP) pode acarretar em boas previsões fora da amostra (amostra de teste).

Quanto maior o número de neurônios (nós) na camada oculta, mais parâmetros livres ela possui e melhor ajustada à amostra de treino será, mas isso pode gerar *overfitting*, levando a uma má generalização. Segundo Khashei et al. (2008) pelo fato de excesso de treino da rede (*overfitting*), os ruídos dos dados de formação começam a ser também ajustados. Outra questão levantada pelos autores é que a determinação do número de nós na camada oculta depende dos dados e não existe regra para definir tal parâmetro.

A decisão do número de defasagens das observações, que está relacionada à estrutura de autocorrelação (não linear) da série histórica e a dimensão do vetor de entrada, é imprescindível para a modelagem da RNA. Estes parâmetros devem ser definidos previamente, para tanto, há a necessidade de realizar experimentos para designá-los, Haykin (2001).

Posteriormente à definição dos padrões de entrada, devem ser separados os padrões de treinamento e teste da rede. O treinamento servirá para definir a estrutura e os parâmetros da rede neural, já os padrões de teste revelaram o erro do ajuste.

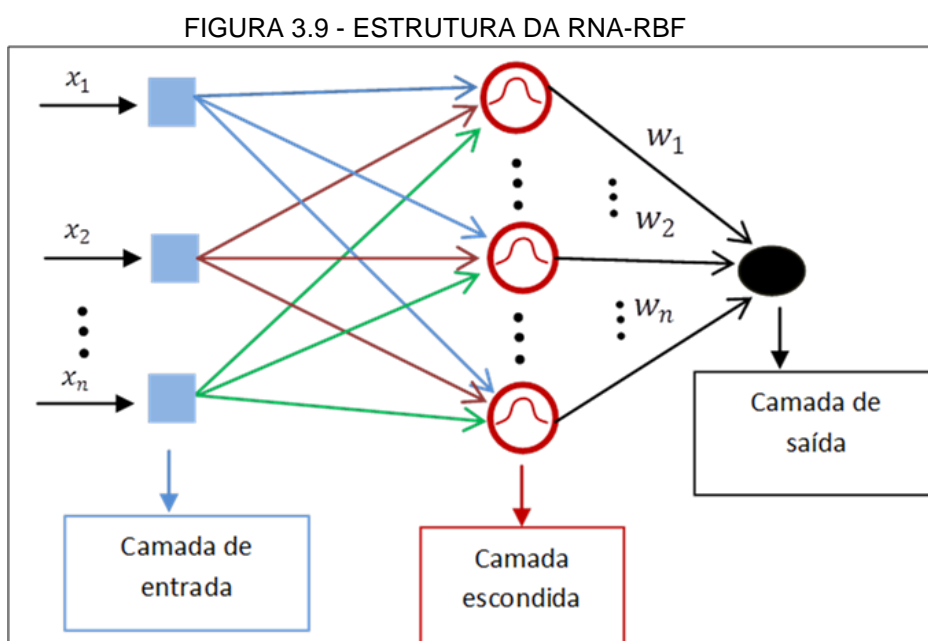
A RNA utilizada nesse trabalho é a RBF, por sua estrutura simples, precisão em aproximação não linear e rápida aprendizagem de padrões complexos e tendências presente nos dados, além de sua rápida adaptação a mudanças dos dados. Sua estrutura é apresentada na Figura 3.9 (HAYKIN, 2001; COELHO e SANTOS, 2011).

Segundo Herrera et al. (2011) a principal diferença entre a RNA-RBF e as demais redes está no tipo de função de transferência utilizada na camada oculta. Esta camada possui uma aprendizagem local, uma vez que cada elemento é responsável pela modelagem de uma seção limitada do espaço de entrada.

A RNA-RBF é composta de três camadas de alimentação diretas (*feedforward*). A camada de entrada são todos os padrões de treinamento, a dimensão desta camada depende da quantidade e da dimensão dos padrões de entrada, os quais estão representados pelos quadrados azuis na Figura 3.9. Esta

camada possui ligações ponderadas com a camada escondida (oculta), que correspondem as setas coloridas na Figura 3.9, aqui representada pela matriz P .

A camada oculta, ilustrada pelos círculos na Figura 3.9, é ativada por uma função não linear, a RBF, que ao ser aplicada as entradas produzem a distância radial entre estes dados e os neurônios da camada oculta (centroides). A unidade de saída (previsão) equivale à elipse preta na Figura 3.9, é definida a partir de uma combinação linear das RBF's e os dados de saída, descrita por meio da matriz denominada por T , que é a resposta do padrão inicial. Esta última matriz será utilizada para a determinação dos pesos da rede, que são ilustrados pelas setas pretas da mesma figura.



FONTE: A autora (2014).

Pode-se considerar que dois mapeamentos são realizados nesta rede. Primeiro um não linear dos dados de entrada, com base nas funções de ativação de bases radiais. O segundo mapeamento dos dados de saída por ponderação linear da camada oculta. A associação entre o vetor de dados de entrada m -dimensional $x \in \mathbb{R}^m$ e o vetor de saída n -dimensional $y \in \mathbb{R}^n$ é apresentada na Figura 3.9, $f: x \rightarrow y$. Caso este mapeamento seja considerado como uma função no espaço de entrada, o problema pode ser entendido como de aproximação de função, sendo assim a aprendizagem seria determinar uma superfície em um espaço multidimensional que produz o melhor ajuste para os dados de treino (COELHO e SANTOS, 2011).

A não linearidade no caso das RNA-RBFs, está no processamento das informações na camada escondida da rede, ou seja, na fase de ativação dos dados por meio das funções de bases radiais. As funções representam uma pequena região referente aos dados de entrada onde são centralizadas e encarregadas de definir o nó (neurônio) de saída, de acordo com um dado de entrada ou um conjunto de entrada.

A função τ , como apresentado na equação (3.12), depende da distância dos padrões de entrada (x) aos centros das bases radiais (c_i) , onde $\| \cdot \|$ é a distância, pode ser empregado qualquer métrica; neste estudo será considerado a Euclidiana e largura b_i das bases radiais.

$$f(x) = \tau \left(\frac{\|x - c_i\|}{b_i} \right) \quad (3.12)$$

onde $x = (x_1, x_2, x_3, \dots, x_m)^T \in \mathbb{R}^m$ é um vetor de entrada da rede m – dimensional e f é a saída da camada escondida (WU et al., 2012).

A informação das distâncias pode ser apresentada através de uma matriz nomeada por D . A matriz D deve ser ativada, como mencionado anteriormente, esta é a maneira com que os neurônios da camada oculta processam a informação x , como se pode observar é necessário definir os centros das bases radiais.

A RNA-RBF emprega dois tipos de aprendizagem: a não supervisionada e a supervisionada como mencionado por Ding et al. (2011). A primeira é aplicada para a definição dos centros das bases radiais, através do agrupamento dos dados de entrada; a segunda na determinação dos pesos da camada de saída por intermédio do método da pseudo inversa.

Os centros podem ser estabelecidos também, através de aprendizagem supervisionada, embora os melhores resultados sejam obtidos quando a não supervisionada é aplicada. Como citado anteriormente os centros, que são os neurônios da camada escondida, são de suma importância para que a rede alcance bons resultados.

A aprendizagem supervisionada é realizada através da apresentação do padrão de entrada da rede e de sua respectiva resposta. Esta informação é utilizada no treinamento, a fim de que os pesos sinápticos sejam calibrados a partir de um método estatístico pré-definido. O método então verifica a diferença entre o dado de saída real e o calculado pela rede, os pesos são alterados até que esta diferença

alcance uma estabilidade conforme Haykin (2001). A aprendizagem não supervisionada ocorre quando se apresenta o padrão de entrada, mas o resultado que este deve obter não é informado à rede.

Após a determinação dos neurônios da camada escondida, a distância entre o padrão de entrada e os centroides são calculados, possibilitando então a ativação das informações por intermédio das funções de bases radiais. Quando o dado de entrada está próximo do centro esta saída terá um valor alto, caso contrário o valor decrescerá a zero (LIAO, 2010), a matriz resultante desta operação é denotada por G .

As funções de ativação mais utilizadas, apresentadas a seguir, são obtidas em Haykin (2001):

- Função Gaussiana:

$$f(x) = \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] \quad (3.13)$$

com média μ (centro da função Gaussiana) e variância σ (informa quão dispersos estão os dados).

- Função sigmóide (função logística):

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.14)$$

- Função tangente hiperbólica:

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}}, \quad x \in \mathbb{R} \quad (3.15)$$

Existe pouca informação a respeito de qual função de base radial utilizar, isso é feito com base na experiência subjetiva segundo Wu et al. (2012).

Tsekouras (2013) afirma que para calcular a largura das bases radiais utiliza a equação apresentada:

$$b_i = \frac{\alpha d_{\max}}{\sqrt{m_1}} \quad (3.16)$$

onde α é um fator positivo e d_{\max} é a distância máxima entre todos os pares do centro do agrupamento e m_1 quantidade de centros.

O cálculo da largura das bases radiais apresentado por Haykin (2001):

$$b = \frac{d_{\max}}{\sqrt{2m_1}} \quad (3.17)$$

Este cálculo torna a largura fixa para as RBF.

Haykin (2001) apresenta a função Gaussiana isotrópica, com desvio padrão definido na equação (3.17), significando que este é fixo a partir do espalhamento dos centros c_i , como segue:

$$G(\|x - c_i\|^2) = \exp\left(-\frac{m_1}{d_{\max}^2} \|x - c_i\|^2\right), \quad i = 1, \dots, m_1 \quad (3.18)$$

A ligação entre os centroides e os neurônios da camada de saída, são os pesos w_i da RNA. Nesta fase do treinamento é conhecida a matriz G e também a matriz T , essas informações são imprescindíveis para o cálculo dos pesos; que são determinados por mínimos quadrados e satisfazem a equação (3.19):

$$G \cdot W = T \quad (3.19)$$

Determinadas as matrizes G e W , a previsão pode ser realizada e com isso o cálculo do erro de treinamento é estabelecido.

Como a matriz G não é quadrada, o cálculo da matriz inversa não é possível, então utiliza-se um método chamado de pseudo-inversa ou matriz inversa de Moore-Penrose, com função semelhante da inversa comum. Este método torna possível a solução das equações lineares. Ding et al. (2013) e Haykin (2001) utilizam a notação $+$ para denotar a pseudo-inversa, logo a equação (3.19) pode ser reescrita como:

$$W = G^+ T \quad (3.20)$$

$$G^+ = (G^T G)^{-1} G^T \quad (3.21)$$

A resolução do sistema (3.21) é similar ao processo de se obter uma distância mínima dos mínimos quadrados em um sistema linear geral.

Os benefícios da RNA-RBF são: possuir menos pesos, o treino é muito rápido e demanda menos amostras. Jafarian *et al.* (2014) e Zheng e Zhong (2011) apontam o fato de que a não-estacionariedade da série, pode ser contornada ao se utilizar o método.

Gan; Peng; Dong (2012), observaram que quanto menor a estrutura da rede mais benefícios esta possui. Por ter menos custo e rapidez computacional, juntamente com a ampliação da capacidade de generalização, evitando o *overfitting* da rede RBF.

3.5.4 Transformação *Wavelet*

Ainda que os primeiros registros das *Wavelets* de Haar datam de 1909, esta permaneceu um longo intervalo de tempo inexplorada, sendo a única base ortonormal *Wavelet* conhecida. Mallat (1989) incentivou a pesquisa em *Wavelet* a partir de sua aplicação em processamento digital de imagem, esta foi usada por Ingrid Daubechies em anos posteriores e suas obras tornaram-se base das *Wavelets* encontradas atualmente (LIMA 2002).

A expansão deste assunto se deve a imprescindibilidade da criação de uma função matemática de duração limitada (domínio finito ou compacto) (MEYER, 1993). A ampliação e redução podem ser realizadas sem o problema da janela temporal, como ocorre com a transformada de janela de tempo Fourier. Outra característica peculiar das *Wavelets* são as irregularidades e assimetrias que possuem, possibilitando com que rápidas alterações da série sejam investigadas por este método, de acordo com Fayal (2008).

As referidas funções eram formadas de pequenas ondas ("*Ondelette*", ondaletas) o que ocasionou o termo em inglês *Wavelets*. Estas são representadas em blocos, possuem propriedades de translação e dilatação em uma única função $\psi_{j,k}(t)$, sendo que a alteração de j e k geram as chamadas *Wavelets* filhas a partir da *Wavelet* mãe $\psi_0(t)$. A *Wavelet* mãe é a função base que é aproximada da série inicial pertencente ao conjunto de funções quadraticamente integráveis $L^2(\mathbb{R})$, essas ondas possuem um valor médio igual a zero,

$$\psi_{j,k}(t) = \frac{1}{\sqrt{j}} \psi_0\left(\frac{t-k}{j}\right); j \neq 0 \quad (3.22)$$

sendo j fator de contração se seu valor aumente e de dilatação caso contrario (escalamento) e k termo de translação. A variação sucessiva desses parâmetros promove a transformada *Wavelet*. Portanto o sinal inicial da série temporal é decomposto em elementos de frequência distintos e cada um deles é analisado conforme uma resolução de escala (BARBOSA; BLITZKOW, 2008 e FAYAL, 2008).

As transformadas *Wavelets* efetuam a decomposição de sinais, no caso estudado séries temporais, em componentes de aproximação e de detalhes que serão estabelecidas através de dilatações e translações. Essas operações geram

um sistema de funções ortonormais, referentes a tempo e frequência segundo Rocha (2008).

Entretanto a separação em componentes, não translada nem rotaciona os pontos de mínimos, máximos ou de inflexão da série observada. Um de seus benefícios está em poder ser aplica-la a séries com características não lineares e não estacionárias (ROCHA 2008).

A variação da janela de tempo utilizada na transformada *Wavelet* está relacionada com a frequência que se quer investigar, frequências altas necessitam de janelas de tempo mais estreitas e de curta duração (componentes de detalhe). Portanto proporcionam uma análise da série em uma escala muito mais detalhada e melhor resolução temporal. Entretanto em frequências menores são requeridas janelas mais largas, ou seja, em uma escala maior (componente de aproximação), menos detalhada, configurando características gerais da série, mais refinada na frequência do que na escala de tempo segundo Barbosa e Blitzkow (2008) e Fayal (2008).

Para evitar a produção de excessivo volume de informações, a *Wavelet* mãe pode ser operada em potências de dois (por meio de posições e escalas diádicas).

A fundamentação da teoria *Wavelet* está posta sobre o espaço de Hilbert (l^2), considere então D e T dois operadores neste espaço e o vetor $\omega \neq 0 \in l^2$, este é um vetor ortonormal *Wavelet* (ou apenas vetor *Wavelet*), se gera uma base ortonormal $\{D^m T^n \omega\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, com $\omega_{m,n} := D^m T^n \omega$ vetores ortonormais *Wavelets* gerados por ω (KUBRUSLY, 2011, LEVAN; KUBRUSLY, 2003 e TEIXEIRA JR 2013).

O subespaço linear fechado de l^2 definido por:

$$W_m(\omega) := \left(\text{span}\{\omega_{m,n}\} \right)^- \quad (3.23)$$

sendo n e $m \in \mathbb{Z}$, é o subespaço de detalhe de nível m . A projeção ortogonal $P_{\omega,m}$ de x sobre $W_m(\omega)$, é o componente de detalhe de nível m do vetor x em l^2 , o símbolo $\langle ; \rangle$ é referente ao produto interno do espaço l^2 (DAUBECHIES, 1988 e TEIXEIRA et al. 2014).

$$P_{\omega,m} := \sum_{n \in \mathbb{Z}} \langle x; \omega_{m,n} \rangle \omega_{m,n} \quad (3.24)$$

Considerando agora qualquer vetor $\phi \neq 0$ em l^2 , gerador do subconjunto $\{D^m T^n \phi\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, tal que $\langle D^{m'} T^{n'} \phi, D^j T^k \phi \rangle = 0$, quando $m' = j$ e $n' \neq k$ caso

contrário $\langle D^{m'}T^{n'}\phi, D^jT^k\phi \rangle \neq 0$ para todo m', n', j e $k \in \mathbb{Z}$, é um vetor *Wavelet* escala, os vetores *Wavelet* escala (vetor escala) $\phi_{m,n} := D^mT^n\phi$ são gerados por ϕ .

$$V_m(\phi) := \left(\text{span}\{\phi_{m,n}\} \right)^- \quad (3.25)$$

é o subespaço linear fechado em H , denominado de aproximação de nível m . A componente de aproximação de nível m , é definida como a projeção de x em $V_m(\phi)$ como segue (TEIXEIRA JR. et al. 2012):

$$P_{\phi,m} := \sum_{n \in \mathbb{Z}} \langle x, \phi_{m,n} \rangle \phi_{m,n} \quad (3.26)$$

A transformada *Wavelet* segundo Mallat (2008) é o produto interno do vetor $x \in H$ e um vetor *Wavelet* ou um vetor escala, sendo que o conjunto de todas as transformações pode ser dividido em dois conjuntos distintos. Coeficientes de detalhes $\{d_{m,n}\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$ e coeficientes de aproximação $\{a_{m,n}\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, estes termos são os produtos internos presentes no cálculo da projeção do vetor x apresentados nas equações (3.24) e (3.26).

De acordo com Teixeira Jr (2013), pode-se realizar a expansão ortogonal, que é única, para todo vetor $x \in H$ segundo a equação (3.27).

$$x = P_{\phi,m_0}(x) + \sum_{m=m_0}^{+\infty} P_{\omega,m}(x) \quad (3.27)$$

ou ainda,

$$x = \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n} + \sum_{m=m_0}^{+\infty} \sum_{n \in \mathbb{Z}} d_{m,n} \omega_{m,n} \quad (3.28)$$


A primeira soma da equação apresenta a tendência da série temporal, componentes de baixa frequência, a segunda parte apresenta os pormenores da série, componentes de alta frequência (MABROUK et al., 2008).

A *Wavelet* Haar foi a primeira a ser elaborada, sua função escala $\phi(x)$ é definida pela equação (3.29) e a função *Wavelet* $\omega(x)$ pela equação (3.30), os gráficos são apresentados na FIGURA 3.10

$$\phi(x) = \begin{cases} 1, & \text{se } x \in [0,1) \\ 0, & \text{caso contrário} \end{cases} \quad (3.29)$$

$$\omega(x) = \begin{cases} 1, & \text{se } x \in \left[0, \frac{1}{2}\right) \\ -1 & \text{se } x \in \left[\frac{1}{2}, 1\right) \\ 0, & \text{caso contrário} \end{cases} \quad (3.30)$$

FIGURA 3.10 - ESTRUTURA HAAR.



FONTE: Teixeira (2015).

Para melhor compreensão da decomposição *Wavelet*, é apresentado um exemplo utilizado por Chaovalit et al. (2011).

Dada a série temporal $S = \{80, 61, 75, 71, 63, 59, 76, 63\}$, considere cada elemento da série como S_i sendo $i = 1, \dots, 8$, considerando a *Wavelet* Haar e nível de decomposição um, aplica-se ao longo de pares da série a função móvel $(S_{n+1} + S_n)/2$ para a obtenção das médias, as diferenças são calculadas por $(S_{n+1} - S_n)/2$. Os resultados são apresentados na tabela

QUADRO 3.4 - EXEMPLO DE DECOMPOSIÇÃO WAVELET HAAR

S	80	61	75	71	63	59	79	63
Média (coeficientes de aproximação)	$\frac{S_2 + S_1}{2} = 70,5$		$\frac{S_4 + S_3}{2} = 73$		$\frac{S_6 + S_5}{2} = 61$		$\frac{S_8 + S_7}{2} = 71$	
Diferença (coeficientes de detalhe)	$\frac{S_2 - S_1}{2} = -9,5$		$\frac{S_4 - S_3}{2} = -2$		$\frac{S_6 - S_5}{2} = -2$		$\frac{S_8 - S_7}{2} = 8$	

FONTE: A autora (2016)

A partir da decomposição Haar tem-se a série de aproximação $A = \{70,5; 70,5; 73; 73; 61; 61; 71; 71\}$ e a série de detalhe $D = \{9,5; -9,5; 2; -2; 2; -2; 8; -8\}$, o valor original é obtido somando elementos equivalentes das decomposições.

Empregando a *Wavelet* Daubichies 2 (Db2) ao exemplo acima e aumentando a quantidade de dados da série, são obtidos os resultados expostos no Quadro 3.5.

QUADRO 3.5 - EXEMPLO DE DECOMPOSIÇÃO WAVELET DB2

y_t^1	A_1^1	D_1^1	y_t^2	A_1^2	D_1^2	y_t^3	A_1^3	D_1^3
80	70,8394	9,1606	80	70,8394	9,1606	80	70,8394	9,1606
61	67,6107	-6,6107	61	67,6107	-6,6107	61	67,6107	-6,6107
75	71,1172	3,8828	75	71,1172	3,8828	75	71,1172	3,8828
71	72,8191	-1,8191	71	72,8191	-1,8191	71	72,8191	-1,8191
63	66,0311	-3,0311	63	66,0311	-3,0311	63	66,0311	-3,0311
59	61,5179	-2,5179	59	61,5179	-2,5179	59	61,5179	-2,5179
79	65,7859	13,214 1	79	66,2369	12,7631	79	64,9097	14,8256
63	67,7010	-4,7010	63	68,4821	-5,4821	63	64,9097	-1,9097
			51	55,8301	-4,8301	51	72,2284	-21,2284
						84	77,7832	6,2168

FONTE: A autora (2016).

Caso a decomposição Db2 fosse realizada apenas para os valores incorporados a série $S^1 = \{51; 84\}$, as séries de decomposição seriam, $A_1^1 = \{70,5197; 78,7697\}$ e $D_1^1 = \{-19,5197; 5,2303\}$.

As operações para a definição das componente utilizando a *Wavelet* Db2 não são as mesmas que a apresentada para a Haar. Cada *Wavelet* possuem funções escala e Wavelet distintas, elas que definem os cálculos a serem realizados. O formato de algumas Wavelets são apresentadas no Apêndice 1.

Pode-se verificar que a inclusão de novos valores a série, gera uma mudança na decomposição dos dados que procedem os valores incorporados. A decomposição apenas dos valores inseridos, não resultam nos mesmos valores de decomposição quando esses são realizados juntamente com os demais dados da série.

O fato da decomposição se alterar a medida que novos valores são adicionados a série, mostra que se for realizada a decomposição para série completa de dados e depois separá-la em treinamento e teste ou se aplicar apenas

a decomposição no conjunto de treinamento e depois no conjunto de teste, isso irá gerar alguns valores distintos na decomposição. A decomposição de apenas um valor não pode ser realizado.

Os trabalhos da literatura, como Liu et al. (2011), Caswell (2014), Zhu et al. (2014) não evidenciam como é realizada a decomposição *Wavelet* dos dados da série, se ela é primeiramente separada em treinamento e teste ou se a decomposição é aplicada a todo o conjunto de dados.

3.5.5 Métodos de Comparação

A comparação do desempenho dos métodos e das previsões é realizada por meio dos seguintes critérios, apresentados por Hair et al. (2009), considerando que y_t é o dado original da série temporal e \hat{y}_t o valor estimado:

- *Sum of squared error* (SSE), soma dos erros quadráticos:

$$SSE = \sum_{t=1}^m |y_t - \hat{y}_t|^2 \quad (3.31)$$

- *Mean Squared Error* (MSE), erro quadrático médio:

$$MSE = \frac{1}{m} \sum_{t=1}^m |y_t - \hat{y}_t|^2 \quad (3.32)$$

A comparação entre métodos pode ser calcula pelo SSE e MSE, isto é realizado para identificar o método que possui o melhor desempenho.

- *Root Mean Squared Error* (RMSE), raiz do erro quadrático médio:

$$RMSE = \sqrt{\frac{\sum_{t=1}^m |y_t - \hat{y}_t|^2}{m}} \quad (3.33)$$

onde $\|y_t - \hat{y}_t\|^2$ é o erro de ajuste para a observação t e m é o número de observações.

- *Mean Absolute Percentage Error* (MAPE), erro médio percentual absoluto:

$$MAPE = \frac{1}{m} \sum_{t=1}^m \left| \frac{y_t - \hat{y}_t}{y_t} \times 100 \right| \quad (3.34)$$

onde \hat{y}_t é o valor estimado (valor ajustado) para o período t , y_t é o valor observado (real).

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (3.35)$$

O RMSE, MAPE e MAE são empregados para verificar a qualidade do ajuste do modelo utilizado.

Os métodos de comparação citados acima podem ser observados nos trabalhos de Scarpin e Steiner (2011), Coelho e Santos (2011), Kia et al. (2012) entre outros.

Jafarian et al. (2014) além dos métodos supracitados, empregam o coeficiente de determinação R^2 definido como:

$$R^2 = \sum_m (y_t)^2 - \frac{\sum_m (y_t - \hat{y}_t)^2}{\sum_m (y_t)^2} \quad (3.36)$$

A estatística Durbin-Watson é um teste de hipótese, que mensura a associação linear entre resíduos adjacentes do modelo de regressão, definido em (3.37).

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} \quad (3.37)$$

onde T é o número de observações, e_t o resíduo associado a observação no tempo t , o valor de d é aproximadamente $2(1-r)$, onde r é a autocorrelação dos resíduos, $d = 2$ indica que não existe autocorrelação.

4 MATERIAIS E MÉTODOS

Neste capítulo são especificadas as metodologias híbridas propostas, que basicamente são compostas pela Decomposição *Wavelet*, a modelagem das decomposições pelo método ARIMA e de seus resíduos por RNA.

Os conjuntos de séries apresentados nos trabalhos de Khashei e Bijari (2011) e Zhang (2003) foram adotados aqui, a fim de se comparar a precisão da metodologia proposta em relação aos trabalhos citados. As séries temporais são: Linces Canadenses³, Manchas Solares de *Wolf*⁴ e taxa de Câmbio⁵.

Além das séries presentes na literatura, a série obtida pelas leituras manuais do instrumento piezômetro, presente na instrumentação do monitoramento da barragem da Usina Hidrelétrica de Itaipu, também foi utilizada.

4.1 SÉRIES TEMPORAIS UTILIZADAS

A especificidade de cada série é apresentada nesta seção, tal como o período de leituras, transformações da série de dados, a quantidade de dados utilizados para fazer a previsão e teste da metodologia. Essas peculiaridades das séries são apontadas tomando como referência os trabalhos de Zhang (2003) e Khashei e Bijari (2011).

A série temporal do piezômetro PS-F-72 da Usina Hidrelétrica de Itaipu, fornecida pelo CEASB (2015), foi caracterizada segundo orientações dos engenheiros da Usina Hidrelétrica de Itaipu, que são responsáveis pelo setor de monitoramento e segurança da barragem.

³ <https://datamarket.com/data/set/22vj/annual-number-of-lynx-trapped-mackenzie-river-1821-1934#!display=line&ds=22vj>


⁴ <http://www.sidc.be/silso/datafiles>

⁵ <https://research.stlouisfed.org/fred2/series/DEXUSUK/downloaddata>

4.1.1 Série temporal dos Linces Canadenses

O número de linces capturados por ano no lago Mackenzie no distrito do norte do Canadá é uma série utilizada também na literatura, relacionada a modelos não lineares.

O período da série considerado é do ano de 1821 a 1934, totalizando 114 dados, são expostos na Figura 4.1.




FONTE: A autora (2016).

O logaritmo na base 10 é aplicado a série, para que o resultado possa ser comparado com os trabalhos da literatura, sendo assim o formato da série que será efetivamente modelada é exposto na Figura 4.2.

Os dados referentes aos anos de 1821 a 1920, são utilizados para o treinamento da metodologia, ou seja 100 dados; os demais dados de 1921 a 1934, o equivalente a 14 dados, fazem parte do conjunto de teste da metodologia. O horizonte de previsão no caso é de 14 anos.

FIGURA 4.2 -LOGARITMO DA SÉRIE DOS LINCES CANADENSES




FONTE: A autora (2016).

4.1.2 Série temporal de Manchas solares de *Wolf*

O estudo da série *Wolf's* de manchas solares é de interesse de climatologistas e geofísicos (ZHANG, 2003). Esta série estima o número de manchas solares por meio de médias anuais; ela é considerada não linear e não Gaussiana, sendo utilizada para a verificação de modelos não lineares mas estudada tanto em modelagens lineares e não lineares.

Ela é composta de 288 observações do número de manchas solares anuais de 1700 a 1987, Figura 4.3. O conjunto de treinamento é composto por 221 dados, equivalentes ao ano de 1700 a 1920, já o conjunto de teste possui 67 elementos, referentes aos anos de 1921 a 1987.

FIGURA 4.3 -SÉRIE TEMPORAL DE MANCHAS SOLARES



FONTE: A autora (2016).


4.1.3 Série temporal da Taxa de Câmbio

A taxa de câmbio semanal entre a libra esterlina e o dólar dos Estados Unidos da América (EUA) é a última série a ser utilizada. Os dados são observações semanais que compreendem o ano de 1980 a 1993, consiste de 731 observações, para que a modelagem seja realizada também é aplicado o logaritmo.

O conjunto de treinamento referente a essa série abrange os anos de 1980 a 1992, totalizando 679 dados da série temporal. O conjunto de teste possui 52 semanas do ano de 1993.

A Figura 4.4 apresenta o gráfico da série de dados, sendo que o eixo x identifica a primeira semana, segunda semana e assim sucessivamente até a última semana considerada que se refere a última semana do mês de dezembro de 1993.

FIGURA 4.4 - SÉRIE TEMPORAL DA TAXA DE CÂMBIO



FONTE: A autora (2016).

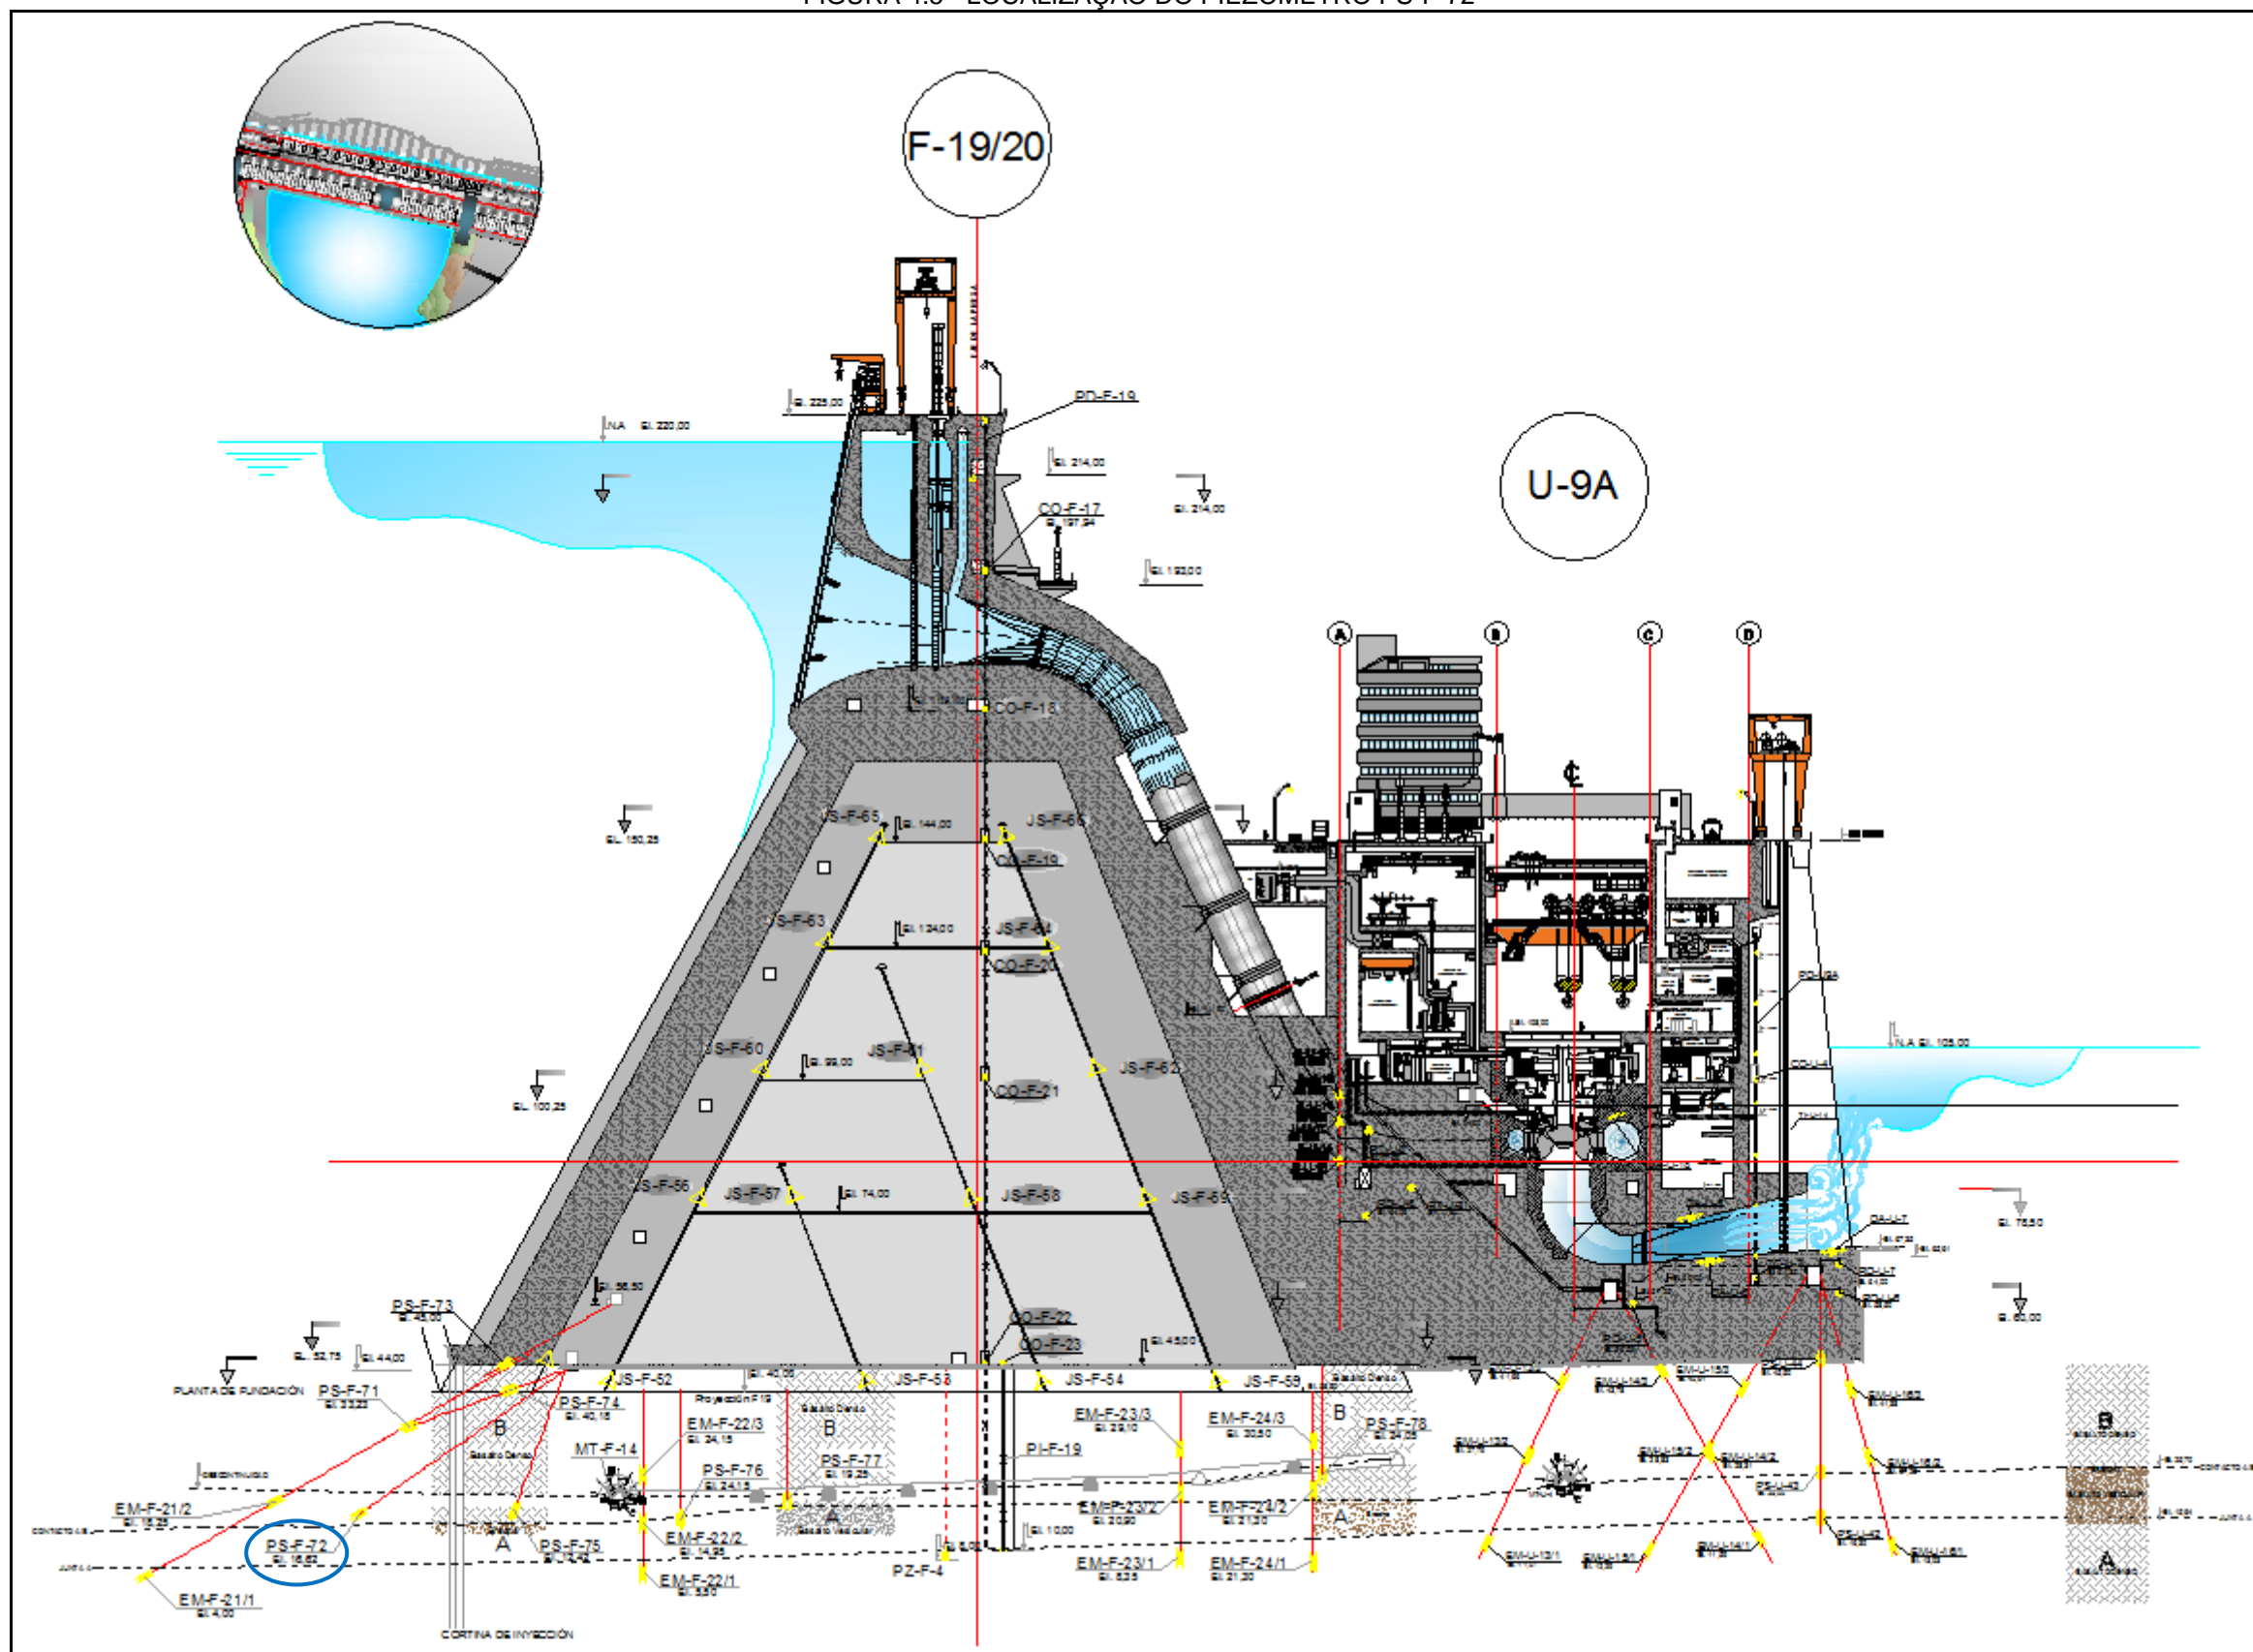
4.1.4 Série temporal do piezômetro PS-F-72

A série do piezômetro localizado na barragem principal, Trecho F, bloco 19/20, é denominada de PS-F-72. Este instrumento possui leituras manuais e automáticas, a análise inicial será realizada a partir de leituras manuais. Este equipamento monitora a brecha entre os derrames basálticos A e B, como observado na Figura 4.5, estando a localização do instrumento circulada em azul.

A instrumentação de auscultação foi instalada durante a construção da barragem da Usina Hidrelétrica de Itaipu, especificamente o piezômetro trabalhado, possui medições desde novembro de 1980. As coletas dos dados eram realizadas em média a cada quatro ou três dias no período de novembro de 1980 a agosto de 1984, após esse período as leituras começaram a ser realizadas a cada sete dias aproximadamente até o mês de fevereiro de 1987. As leituras começam a ser espaçadas em média de 14 dias a partir de março de 1987 até os dias atuais.

A série histórica deste instrumento engloba leituras de antes do enchimento do lago da Usina Hidrelétrica de Itaipu. Silveira (2006) sugere que o estudo do comportamento das leituras deve ser realizado extraindo os dados da fase após o enchimento do lago, pelo fato de não haver se estabelecido um equilíbrio na estrutura e fundação.

FIGURA 4.5 - LOCALIZAÇÃO DO PIEZÔMETRO PS-F-72




FONTE: CEASB (2015).

As leituras datam de janeiro de 1986 a outubro de 2014. Essas podem ser apresentadas em metros de coluna d'água (*mca*) ou em metros sobre o nível do mar (*msnm*). Por indicação dos engenheiros especialistas em monitoramento de barragens, as leituras serão referentes à *mca*.

A série foi suavizada, a fim de se obter dados mensais, visto que a série não é igualmente espaçada. A média mensal dos dados das leituras manuais foi realizada, sendo que a quantidade de leituras por mês variam de 4 a 1.

A Figura 4.6 apresenta a série temporal do piezômetro PS-F-72 estudada. A série até fevereiro de 1992 possui uma tendência e está em uma faixa de 100 à 85 *mca*. Em setembro de 1992 há uma diminuição brusca para 79 *mca*. A partir desta data os dados ficam na faixa de 80 a 70 *mca* até o mês de junho de 2005, onde se obtém valores menores que esta faixa, logo após os valores aumentam. Em setembro de 2006, a faixa de valores se altera entre 69 e o mínimo é obtido em 65 *mca*, isso ocorre até outubro de 2009. Os valores do piezômetro a partir daí são de aproximadamente 70 *mca*, até fevereiro de 2013. A faixa dos dados diminui para 65 em média até a última leitura utilizada neste estudo de outubro de 2014



FONTE: A autora (2016).

O interesse na análise do gráfico é sua tendência e a variação dos dados de leitura do instrumento, ao longo do tempo, apresentado na Figura 4.6. Os limites de projeto para o PS-F-72 são de 0 à 136,82 *mca*, já os da série histórica observada são 63,99 à 100,59 *mca*. São observados pela equipe de monitoramento e segurança da barragem, os valores que excedem o registro histórico e a variação

entre leituras que excedem a 10%, no caso específico do instrumento nesta localidade. Estas informações são utilizadas para configurar um alerta, CEASB (2015).

A série de dados é separada em conjunto de treinamento, composto por 312 dados referentes aos meses de janeiro de 1986 a setembro de 2012, enquanto que o conjunto de teste contém 24 observações dos meses de outubro de 2011 a outubro de 2014, dois anos de previsão. O horizonte de tempo de previsão é considerado satisfatório, para que se possa realizar algum tipo de medidas preventivas, caso seja identificado tendências indesejáveis com relação a leitura do instrumento.

4.2 MÉTODOS HÍBRIDOS PROPOSTOS

A nova metodologia terá como bases os trabalhos desenvolvidos por Jiurian e Bingfeng (2013), Zheng e Zhong (2011), Khashei e Bijari (2011) e Zhang (2003).

A estrutura das metodologias propostas podem ser verificadas através do fluxograma da Figura 4.7 e Figura 4.8.

A metodologia 1 é composta pelas seguintes fases:

1. Decomposição *Wavelet* de nível 2 da série de dados;
2. Realização da modelagem ARIMA de cada série da decomposição;
3. Combinação das modelagens ARIMA, gerando \hat{y}_t ;
4. Cálculo do erro da modelagem combinada, gerando e_t ;
5. Decomposição de nível 2 na série de resíduos;
6. Modelagem dos resíduos por meio da RNA, \hat{e}_t ;
7. Combinação de \hat{y}_t e \hat{e}_t ;
8. Determinação da previsão final.

A DW foi realizada por meio do *software* Matlab® de duas maneira distintas, uma apenas ao conjunto de treinamento e outra considerando toda a série. A modificação da quantidade de elementos decompostos altera uma parte das

decomposições, logo não é possível fazer a decomposição de apenas uma observação da série, por esta razão foi adotada esta estratégia.

As decomposições, apenas dos dados de treinamento, foram utilizadas para fazer a previsão da série temporal. A previsão a RNA-RBF é definida de duas formas, um e n passos a frente. No caso da previsão um passo a frente, denotado por Prev_Rbf1, os dados originais do conjunto de teste foram substituídos pela previsão de seu elemento equivalente, sendo assim as previsões dos elementos subsequentes necessitam da previsão dos anteriores. A previsão n passos a frente, denotado por Prev_RBFn, determina a previsão dos n valores do horizonte de previsão de uma única vez.

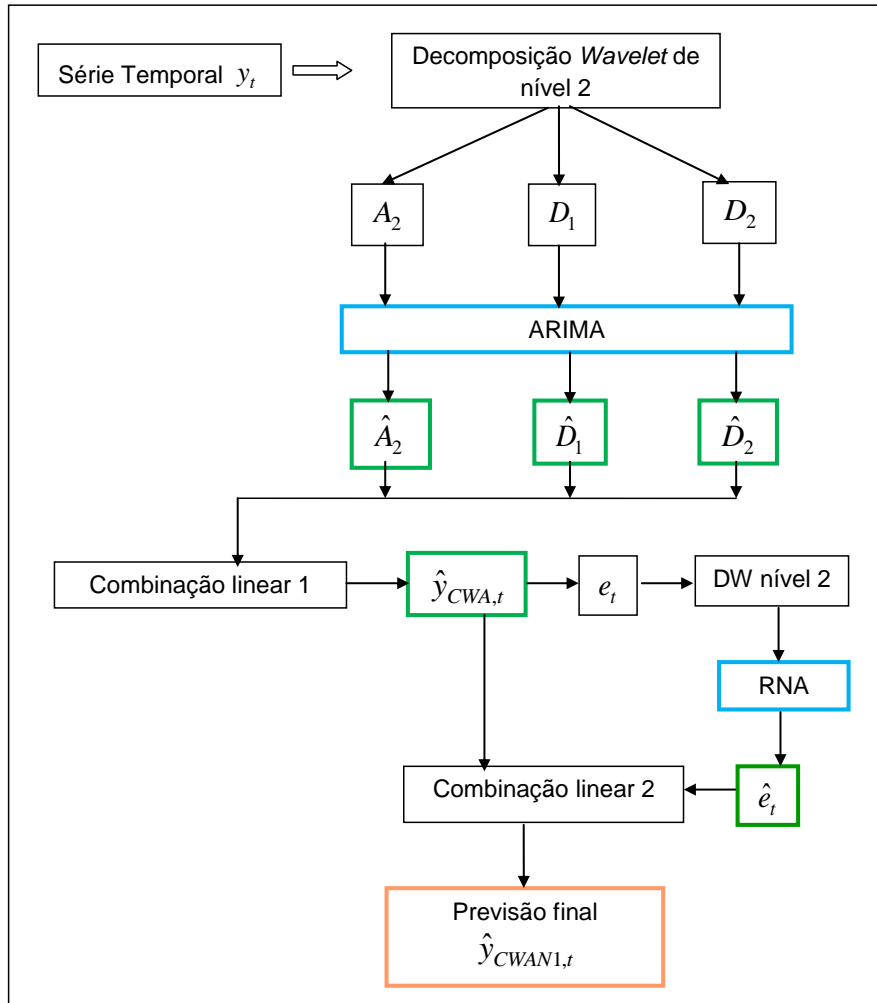
A decomposição de toda a série temporal foi aplicada para realização do ajuste do teste da série temporal, simbolizada por Aj_RBF1, este utiliza o próprio elemento da série para prever os próximos.

O tipo de *Wavelet* empregada altera os valores da decomposição, por este motivo se faz necessário identificar a *Wavelet* mais apropriada ao conjunto de dados. Uma metodologia teria que ser desenvolvida apenas para essa identificação, mas como o objetivo geral desta tese é a previsão, optou-se em simplificar esta análise, fez-se testes com diversas *Wavelets*.

Para a definição da *Wavelet* foi utilizada a diferença entre a componente de aproximação da série e a série inicial, considerando as *Wavelets*: Haar, Daubichies (Db2, Db5, Db25, Db45), Symlet (Sym2, Sym6) e Coiflet (Coif1, Coif2, Coif5), os gráficos de cada uma delas é apresentada no Apêndice 1. Foi realizada a busca da maior diferença entre cada decomposição e a série real, após isso identificou-se qual *Wavelet* possui a menor diferença e sendo essa a escolhida para desenvolver o restante do processo. As *Wavelet* investigadas foram identificadas em trabalhos citados anteriormente.

A identificação da estrutura e a definição dos parâmetros do modelo ARIMA, é realizada por meio do conjunto de treinamento (dados dentro da amostra), para auxiliar esta tarefa os gráficos da FAC e FACP, o valor de R^2 e do teste de Durbin-Watson são observados. Estabelecido o modelo, este é aplicado ao conjunto de teste (dados fora da amostra), gerando o ajuste e a previsão a partir da estrutura definida. O *software* E-views 8® é utilizado nesta fase.

FIGURA 4.7 - METODOLOGIA PROPOSTA HÍBRIDA 1



FONTE: A autora (2016).

A combinação dos modelos ARIMA da DW é definido pela equação (4.1).

$$\hat{y}_t = \alpha_{A_2} \hat{A}_{2,t} + \alpha_{D_1} \hat{D}_{1,t} + \alpha_{D_2} \hat{D}_{2,t} \quad (4.1)$$

onde \hat{A}_2 , \hat{D}_1 até \hat{D}_2 são os valores ajustados das séries de decomposição. Os pesos α_{A_2} , α_{D_1} e α_{D_2} são calculados por intermédio de um Problema de Programação Não Linear, cuja função objetivo é definida pelas equações (4.2) e (4.3), onde T é a quantidade de dados do conjunto de treinamento, esse problema foi resolvido utilizando *Microsoft Excel*:

$$\min \text{MSE} = \frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2 \quad (4.2)$$

$$\text{s.a. } \alpha_{A_2}, \alpha_{D_1} \text{ e } \alpha_{D_2} \text{ irrestritas} \quad (4.3)$$

Definido os pesos nesta fase, a combinação é aplicada ao conjunto de teste, em alguns trabalhos da literatura, como em Zhang (2003), a combinação é realizada simplesmente somando as previsões.

O método ARIMA neste contexto também pode ser considerado como um filtro linear, retirando da série a autodependência linear entre os dados. Assume-se que os resíduos da primeira fase de previsão e_t possuem autodependência não linear modelável, sendo assim utiliza-se a RNA para tal.

A DW é aplicada aos resíduos, esta também é uma das características peculiares da metodologia proposta. As séries resultantes formam o padrão de entrada da rede neural e os dados referentes a decomposição são os dados de saída da rede.

A RNA-RBF realiza o ajuste e a previsão dos resíduos, sua implementação foi realizada em *Visual Basic*.

O tamanho da janela de previsão foi avaliado considerando o intervalo de 4 a 8. A investigação da quantidade de neurônios foi realizada entre 3 a 10% da quantidade de padrões da rede, esses valores são apresentados em alguns trabalhos da literatura. Cada janela de previsão foi testada 5 vezes em relação a cada quantidade de centroides totalizando 200 testes. Considerando que foi desenvolvida uma estrutura para ajuste e uma para previsão, atinge-se um total de 400 testes apenas em relação a RNA.

Na fase final do fluxograma da Figura 4.7, a combinação linear 2 do ajuste ARIMA e o resíduo são realizados por meio da equação (4.4).

$$\hat{y}_{CWAN1,t} = \beta \hat{y}_{CWA,t} + \delta \hat{e}_t \quad (4.4)$$

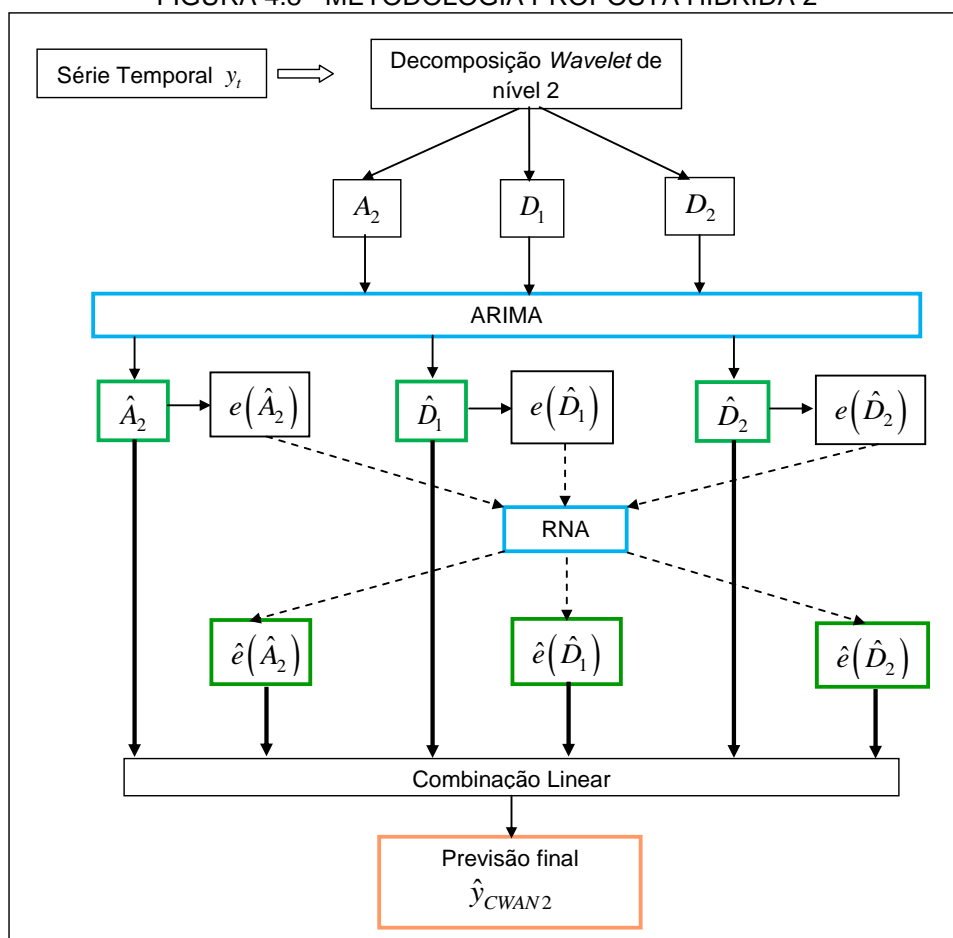
Os pesos da combinação β e δ , também são calculados por meio da resolução de um problema de programação não linear, semelhante ao citado anteriormente.

Não se aplica a previsão um passo a frente dos resíduos na metodologia 1, pelo fato de que cada valor previsto novo deveria ser decomposto para que outro padrão fosse criado, como isso não é possível a menos que toda a série seja decomposta novamente, optou-se em não empregar esse tipo de previsão. Uma análise mais minuciosa se faz necessária para que essa configuração seja aplicada.

A metodologia 2 é apresentada no fluxograma da Figura 4.8, ela é composta pelas seguintes fases:

1. Decomposição *Wavelet* de nível 2 da série de dados;
2. Realização da modelagem ARIMA de cada série da decomposição;
3. O resíduo de cada modelagem ARIMA é calculado em relação a decomposição realizada no início do processo, $e(\hat{A}_2)$, $e(\hat{D}_1)$, $e(\hat{D}_2)$;
4. Cada série do resíduo é modelada pela RNA, $\hat{e}(\hat{A}_2)$, $\hat{e}(\hat{D}_1)$, $\hat{e}(\hat{D}_2)$;
5. Combinação de todos os ajustes $\hat{y}_{CWAN2,t}$.

FIGURA 4.8 - METODOLOGIA PROPOSTA HÍBRIDA 2



FONTE: A autora (2016).

A modelagem RNA-RBF dos resíduos de cada componente de decomposição foi investigada baseada nos mesmos parâmetros da RNA da metodologia 1. A única diferença é que nesta metodologia é possível fazer a previsão um passo a frente, sendo assim foram realizados 1800 testes.

A combinação linear dos ajustes realizada na fase 5 pode ser definida de três formas diferentes, apresentadas nas equações (4.5), (4.6) e (4.7), sendo os

pesos η calculados também por meio de um problema de programação não linear análogo ao apresentado anteriormente.

$$\hat{y}_{CWAN2,t} = \eta_1 \hat{A}_{2,t} + \eta_2 \hat{e}(\hat{A}_{2,t}) + \eta_3 \hat{D}_{1,t} + \eta_4 \hat{e}(\hat{D}_{1,t}) + \eta_5 \hat{D}_{2,t} + \eta_6 \hat{e}(\hat{D}_{2,t}) \quad (4.5)$$

$$\hat{y}_{CWAN2,t} = \eta_1 \hat{A}_{2,t} + \hat{e}(\hat{A}_{2,t}) + \eta_2 \hat{D}_{1,t} + \hat{e}(\hat{D}_{1,t}) + \eta_3 \hat{D}_{2,t} + \hat{e}(\hat{D}_{2,t}) \quad (4.6)$$

$$\hat{y}_{CWAN2,t} = \hat{A}_{2,t} + \hat{e}(\hat{A}_{2,t}) + \hat{D}_{1,t} + \hat{e}(\hat{D}_{1,t}) + \hat{D}_{2,t} + \hat{e}(\hat{D}_{2,t}) \quad (4.7)$$

Todos os parâmetros definidos no processo de treinamento são aplicados ao conjunto de teste.

Esta metodologia gera três classes de modelos em relação ao ajuste e ao tipo de previsão (1 passo e n passos a frente) e três configurações para a combinação, sendo uma combinação linear composta de 6 pesos, equação (4.5), ou seja, um pesos associando a cada previsão dos componentes e de seus resíduos. O segundo tipo de combinação linear aplica pesos apenas a previsão das componentes de decomposição equação (4.6) e soma as previsões dos resíduos dessas componentes. A última combinação linear é a soma das previsões das componentes e de seus resíduos, equação (4.7).

5 RESULTADOS E DISCUSSÕES

A aplicação das metodologias às séries, especificadas anteriormente, é realizada neste capítulo. A definição do tipo de *Wavelet* empregada especificamente em cada fase, as estruturas dos modelos ARIMA e de RNAs são descritas, bem como a comparação das metodologias propostas e das apresentadas na literatura.

As metodologias propostas foram inicialmente aplicadas as séries de dados decompostos pela *Wavelet* Haar realizando apenas a aplicação do modelo ao conjunto de teste do modelo ARIMA e RNA-MLP, essa análise preliminar pode ser constatada em Pereira et al. (2015) e Pereira et al. (2016), muito embora tenham sido preliminares obteve-se resultados promissores.

Cada série é melhor ajustada a uma determinada *Wavelet*, que são apresentadas no Quadro 5.1. A seleção é baseada na componente de aproximação das decomposições, como descrito na seção 4.2. O mesmo procedimento foi realizado para a seleção da *Wavelet* dos resíduos. Pelo fato dos resíduos terem um comportamento parecido, a mesma *Wavelet* foi utilizada em todas as séries. A decomposição dos resíduos é realizada apenas para a aplicação da metodologia 1. Para a série da Usina Hidrelétrica de Itaipu foi aplicada apenas a metodologia 2, sendo assim os resíduos não precisaram ser decompostos.

O nível de decomposição para todas as séries é igual a dois, sendo assim é gerado uma série de componentes de aproximação A_2 e duas séries de componentes de detalhe, D_1 e D_2 , essas novas séries são modeladas pela metodologia proposta.

QUADRO 5.1 - IDENTIFICAÇÃO DAS WAVELETS UTILIZADAS

SÉRIES TEMPORAIS	WAVELET	
	Dados Originais	Resíduos do modelo
Linces Canadenses	Db 45	Coif 5
Manchas solares Wolf	Coif 5	Coif 5
Taxa de Câmbio	Sym 6	Coif5
Piezômetro PS-F-72	Db 45	-

FONTE: A autora (2016).

A decomposição *Wavelet* é aplicada ao conjunto de treinamento a estrutura e os parâmetros dos modelos são definidos. A decomposição de todo o conjunto de dados é utilizada quando a previsão um passo a frente é realizada. Após a decomposição dos dados, estes são separados em treinamento e teste, mas os parâmetros e modelos definidos apenas para o conjunto de treino é aplicado neste segundo caso.

5.1 METODOLOGIAS PROPOSTAS APLICADAS A SÉRIE DOS LINES CANADENSES

Conforme descrito no Quadro 5.1 a série temporal é decomposta pela *Wavelet* Db45, o conjunto de treinamento das séries geradas são utilizadas para a definição da estrutura do modelo ARIMA para cada uma delas. Os modelos de cada série de decomposição é exposta no Quadro 5.2, para melhor modelagem da série A_2 , foi necessário aplicar logaritmo.

QUADRO 5.2 - MODELO ARIMA DAS COMPONENTES WAVELET DA SÉRIE LINES CANADENSES

COMPONENTES WAVELET	NÚMERO DE DIFERENCIAÇÕES	MODELO ARIMA	R^2	DURBIN-WATSON
A_2	1	$+2,11 \cdot AR(1) - 2,16 \cdot AR(2) +$ $+1,22 \cdot AR(3) - 0,42 \cdot AR(4) +$ $+0,10 \cdot AR(7) - 0,77 \cdot MA(2) +$ $-0,20 \cdot MA(3)$	0,9797	2,009
D_1	0	$+1,84 \cdot AR(1) - 2,71 \cdot AR(2) +$ $+1,94 \cdot AR(3) - 1,09 \cdot AR(4) +$ $+0,10 \cdot AR(5) + 0,01 \cdot MA(1) +$ $-1,43 \cdot MA(2) + 0,44MA(6)$	0,9969	1,837
D_2	0	$-3,59 \cdot MA(1) + 4,87 \cdot MA(2) +$ $-2,96 \cdot MA(3) + 0,68 \cdot MA(4)$	0,9651	2,380


FONTE: A autora (2016).

A previsão do conjunto de teste foi realizada como estabelecido na metodologia, o ajuste e a previsão, para cada série da componente de decomposição. O resultado pode ser averiguado na Figura 5.1, Figura 5.2 e Figura 5.3.

A notação A_j identifica que o modelo definido pelo conjunto de treinamento é aplicado ao dados do conjunto de teste, enquanto $Prev$ denota a previsão do conjunto de teste considerando os parâmetros do modelo determinados pelo conjunto de treinamento. Os eixos não estão especificados, por se tratarem da decomposição da série. Pode-se observar que para os componentes de detalhe existem valores negativos perdendo assim o significado de quantidade.


A decomposição do conjunto de teste aqui representada pela linha vermelha com marcadores, foi realizada considerando todo o conjunto de dados. O ajuste do conjunto de teste é efetuado em relação a essa decomposição, ressaltando que o modelo é definido pelo conjunto de treino e aplica-se os dados de teste ao modelo definido, enquanto que a previsão foi calculada sem a utilização desses dados.

FIGURA 5.1 - MODELAGEM ARIMA APLICADA AO CONJUNTO DE TESTE A_2 DOS LINES CANADENSES




FONTE: A autora (2016).

FIGURA 5.2 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_1 DOS LINES CANADENSES



FONTE: A autora (2016).

FIGURA 5.3 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_2 DOS LINES CANADENSES



FONTE: A autora (2016).

Verifica-se a partir de Prev_ que a medida que a serie de dados é substituída pela previsão, para que a próxima previsão seja realizada, a precisão é prejudicada; o que não ocorre no ajuste, pois para prever a próxima observação o dado real da série é utilizado.

Até esta etapa as metodologias 1 e 2 são iguais, a modelagem e as previsões realizadas são empregadas em ambas as metodologias. As próximas seções apresentam a continuidade de cada metodologia.

5.1.1 Metodologia 1 aplicada a série dos Lincos Canadenses

Para que seja possível a continuidade da metodologia 1 é necessário que o ajuste de treinamento dessas séries sejam combinadas linearmente para se obter a previsão da série inicial. Os pesos da combinação linear, como descrito no capítulo de materiais e métodos, são calculados a partir de um problema de programação não linear. A equação (5.1) representa a combinação calculada para o conjunto de treinamento.

$$\hat{y}_{CWA,t} = 0,9998\hat{A}_{2,t} + 1,0000\hat{D}_{1,t} + 0,8711\hat{D}_{2,t} \quad (5.1)$$

A combinação definida é aplicada ao ajuste e a previsão do conjunto de teste, que foram apresentados nos gráficos anteriores.

Os resíduos dessa modelagem foram decompostos por meio da *Wavelet* COIF5, nesta fase busca-se extrair a autodependência não linear que a série possa apresentar, para tanto foi empregado a RNA-RBF.

A estrutura das redes empregadas é apresentada no Quadro 5.3. Os padrões são formados a partir das séries de decomposição dos resíduos, ou seja, de três séries, sendo assim, a quantidade de elementos do padrão no quadro citado se refere ao total de elementos que os compõem.

QUADRO 5.3 - ESTRUTURA DA RNA DA METODOLOGIA 1 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DOS LINCOS CANADENSES

REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/CENTROIDES NA CAMADA OCULTA.	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
Aj_RBF1	3	5	1
Prev_RBFn	21	4	14

FONTE: A autora (2016).

Para exemplificar a formação do padrão, tomamos como base a quantidade de 3 elementos para Aj_RBF1, o padrão consiste em 1 elemento da série A_{2R} , 1 elemento da série D_{1R} e 1 elemento da série D_{2R} , dispostos nesta ordem no

padrão, o valor de saída é o próximo dado da série de resíduos, a janela do padrão é deslocado em um valor e se repete o processo definindo todos os padrões.

No caso da RNA Prev_RBFn, n passos a frente, os padrões de entrada são estabelecidos da mesma forma, a diferença está no fato de que esses padrões estão relacionadas as saídas de 14 valores seguintes da série original dos resíduos. Neste caso a previsão do conjunto de teste foi realizado para o horizonte de 14 anos em uma única vez.


O ajuste do treinamento dos resíduos, por meio da RNA, foi combinado com o ajuste de treinamento definido pela combinação dos modelos ARIMA das séries de decomposição, $\hat{y}_{CWA,t}$, resultando nas equações (5.2) e (5.3). Estas são aplicadas ao conjunto de teste da série, utilizando a previsão dos resíduos no horizonte de tempo determinado.

$$\hat{y}_{CWAN1,Aj_RBF1} = 1,000\hat{y}_{CWA,t} + 1,000\hat{e}_{t,Aj_RBF1} \quad (5.2)$$

$$\hat{y}_{CWAN1,Prev_RBFn} = 1,000\hat{y}_{CWA,t} + 0,991\hat{e}_{t,Prev_RBFn} \quad (5.3)$$

A previsão do conjunto de teste é apresentada na Figura 5.4. Pode-se averiguar que o resultado, adotando a previsão do modelo ARIMA e da RNA-RBF, o resultado não é tão preciso em comparação com o ajuste um passo a frente.

FIGURA 5.4 - RESULTADO DA METODOLOGIA 1 PARA O CONJUNTO DE TESTE DA SÉRIE DOS LINCES CANADENSES



FONTE: A autora (2016).

A utilização da previsão do modelo ARIMA ao invés do ajuste, em relação ao conjunto de teste, gera resíduos com mais erros intrínsecos. Estes erros são inseridos a cada previsão ARIMA subsequente do conjunto de teste. A Prev_RBFn dos resíduos, para o conjunto de teste, não recebe qualquer informação sobre esse conjunto e efetua a previsão de uma única vez de todo o horizonte de previsão de 14 anos. Essa estrutura faz com que a precisão do modelo seja comprometida a cada previsão.

5.1.2 Metodologia 2 aplicada a série dos Lincos Canadenses

A aplicação da metodologia 2 tem início a partir do cálculo dos resíduos de cada modelagem ARIMA das séries decompostas. Os resíduos são modelados por meio da RNA-RBF, considerando ajuste e a previsão um passo e n passos a frente do conjunto de teste.

A estrutura da RNA adotada a cada série de resíduo é apresentada no Quadro 5.4, pode-se observar também que foram realizadas várias configurações para cada série de resíduos. A quantidade de elementos no padrão de entrada é menor do que a adotada na metodologia 1, pelo fato das séries serem modeladas isoladamente ao contrário do que ocorre na metodologia1.

QUADRO 5.4 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DOS LINCOS CANADENSES

COMPONENTE DE DECOMPOSIÇÃO	REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/ CENTROIDES NA CAMADA OCULTA	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
A_{2R}	Aj_RBF1	5	8	1
	Prev_RBF1	6	6	1
	Prev_RBFn	5	4	14
D_{1R}	Aj_RBF1	7	5	1
	Prev_RBF1	4	8	1
	Prev_RBFn	6	4	14
D_{2R}	Aj_RBF1	6	5	1
	Prev_RBF1	4	7	1
	Prev_RBFn	7	6	14

FONTE: A autora (2016).

Os modelos de previsão são apresentados no QUADRO 5.5, como a última combinação possível é a soma das previsões, ela não foi anexada ao quadro.

QUADRO 5.5 - MODELOS DE PREVISÃO DA METODOLOGIA 2 PARA A SÉRIE DOS LINCES CANADENSES

REDE NEURAL	QUANTIDADE DE PESOS NA COMBINAÇÃO	MODELO
Aj_RBF1	6	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + 1,008\hat{A}_{2R} + 1,006\hat{D}_1 + 0,806\hat{D}_{1R} + 1,035\hat{D}_2 + 1,362\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + \hat{A}_{2R} + 1,005\hat{D}_1 + \hat{D}_{1R} + 0,997\hat{D}_2 + \hat{D}_{2R}$
Prev_RBF1	6	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + 1,009\hat{A}_{2R} + 1,008\hat{D}_1 + 0,101\hat{D}_{1R} + 0,934\hat{D}_2 + 0,934\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + \hat{A}_{2R} + 1,014\hat{D}_1 + \hat{D}_{1R} + 0,946\hat{D}_2 + \hat{D}_{2R}$
Prev_RBFn	6	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + 1,006\hat{A}_{2R} + 1,004\hat{D}_1 + 0,073\hat{D}_{1R} + 0,909\hat{D}_2 + 0,817\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + \hat{A}_{2R} + 1,011\hat{D}_1 + \hat{D}_{1R} + 0,926\hat{D}_2 + \hat{D}_{2R}$


FONTE: A autora (2016).

Os coeficientes dos modelos não possuem uma diferença considerável em relação a soma das previsões, como pode ser observado pelos valores do quadro. Algumas exceções são observadas para o caso Prev_RBF1 e Prev_RBFn, sendo as combinações com 6 pesos, cujos coeficientes menores estão associados a previsão dos resíduos de algum componente de detalhe. Vale salientar que os coeficientes de detalhe em relação a essa série têm ordem de grandeza menores do que a série original.

Os pesos das combinações são calculados por intermédio dos dados do conjunto de treinamento, fazendo com que o modelo tenha um melhor ajuste para este conjunto. Mas isso pode não gerar melhorias vinculadas ao conjunto de teste, isso pode ser analisado através dos resultados apresentados na Tabela 5.1.


A aplicação da metodologia 2 ao conjunto de teste, pode ser observada na Figura 5.5 e Figura 5.6, apenas a previsão é exposta visto que o ajuste possui uma excelente adequação aos dados.

FIGURA 5.5 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DOS LINCES CANADENSES



FONTE: A autora (2016).

FIGURA 5.6 - PREVISÃO N PASSOS A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DOS LINCES CANADENSES




FONTE: A autora (2016).

A utilização da Prev_RBF1, com previsão um passo a frente, atinge melhores resultados do que a Prev_RBFn. Essa característica pode ser atribuída ao

fato de nenhuma informação sobre o conjunto de teste, nem mesmo as previsões, são fornecidas para a extrapolação de valores futuros.

A Figura 5.7 apresenta o modelo Box e Jenkins utilizados nos trabalhos base e a previsão n passos a frente em relação ao mesmo modelo.

FIGURA 5.7 - PREVISÃO AR(12) DO CONJUNTO DE TESTE DA SÉRIE DOS LINCES CANADENSES



FONTE: A autora (2016).

A notação $Aj_AR(12)$ refere-se ao ajuste do conjunto de teste e $Prev_AR(12)$ a previsão. A característica da previsão um passo a frente também é verificada na metodologia Box e Jenkins. Como o horizonte de previsão é relativamente pequeno a distinção entre o ajuste um passo a frente e previsão um passos a frente existe, mas não é tão acentuada.

TABELA 5.1 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DOS LINES CANADENSES

METODOLOGIA	MSE	MAE	RMSE
CWAN1_Aj_RBF1	1,391 x10⁻⁴	1,028 x10⁻²	1,179 x10⁻¹
CWAN1_Prev_RBFn	2,310 x10 ⁻¹	4,168 x10 ⁻¹	4,806 x10 ⁻¹
CWAN2_Aj_RBF1_6P	7,247 x10⁻⁵	6,658 x10⁻³	8,513 x10⁻³
CWAN2_Aj_RBF1_3P	5,387 x10⁻⁵	5,334 x10⁻³	7,340 x10⁻³
CWAN2_Aj_RBF1_Soma	4,869 x10⁻⁵	5,305 x10⁻³	6,978 x10⁻³
CWAN2_Prev_RBF1_6P	3,372 x10 ⁻²	1,266 x10 ⁻¹	1,836 x10 ⁻¹
CWAN2_Prev_RBF1_3P	3,356 x10 ⁻²	1,262 x10 ⁻¹	1,832 x10 ⁻¹
CWAN2_Prev_RBF1_Soma	3,370 x10 ⁻²	1,264 x10 ⁻¹	1,836 x10 ⁻¹
CWAN2_Prev_RBFn_6P	2,301x10 ⁻¹	4,168 x10 ⁻¹	4,797 x10 ⁻¹
CWAN2_Prev_RBFn_3P	2,300 x10 ⁻¹	4,168 x10 ⁻¹	4,796 x10 ⁻¹
CWAN2_Prev_RBFn_Soma	2,302x10 ⁻¹	4,176 x10 ⁻¹	4,798 x10 ⁻¹
Aj_AR(12)	3,207x10 ⁻²	1,404 x10 ⁻¹	1,791 x10 ⁻¹
Prev_AR(12)	3,592 x10 ⁻¹	5,232 x10 ⁻¹	5,993 x10 ⁻¹
RNA-MLP	2,046 x10 ⁻²	1,121 x10 ⁻¹	-
Zhang (2003)	1,723 x10 ⁻²	1,040 x10 ⁻¹	-
Aladag et al. (2009)	9,000 x10 ⁻³	-	-
Zheng; Zhong (2011)	-	-	4,69 x10 ⁻²
Khashei; Bijari (2011)	9,900 x10 ⁻³	8,506 x10 ⁻²	-
Adhikari; Agrawal (2014)	1,15 x10 ⁻²	-	-

FONTE: A autora (2016).

A partir da Tabela 5.1, pode-se constatar que o ajuste possui precisão superior as previsões e aos modelos da literatura.

Os modelos que empregam a previsão um passo ou n passos a frente embora tenham resultados inferiores, são de fato previsões, sem conhecimento dos dados reais do conjunto de teste, o que é de grande interesse em aplicações práticas.

5.2 METODOLOGIAS PROPOSTAS APLICADAS A SÉRIE DAS MANCHAS SOLARES WOLF

A série temporal das Manchas solares é decomposta pela *Wavelet* Coif5, o conjunto de treino das séries decompostas provê a identificação do modelo ARIMA. O modelo para cada uma dessas séries é apresentado no Quadro 5.6.


QUADRO 5.6 - MODELO ARIMA DAS COMPONENTES WAVELET DA SÉRIE MANCHAS SOLARES

COMPONENTES WAVELET	NÚMERO DE DIFERENCIAÇÕES	MODELO ARIMA	R^2	DURBIN-WATSON
A_2	1	$+2,68 \cdot AR(1) - 3,43 \cdot AR(2) +$ $+2,73 \cdot AR(3) - 2,65 \cdot AR(4) +$ $+3,20 \cdot AR(5) - 2,69 \cdot AR(6) +$ $+0,966 \cdot AR(7) - 0,09 \cdot AR(10)$	0,996	1,771
D_1	1	$-3,96 \cdot AR(1) - 8,40 \cdot AR(2) +$ $-13,07 \cdot AR(3) - 15,80 \cdot AR(4) +$ $-15,16 \cdot AR(5) - 11,64 \cdot AR(6) +$ $-6,93 \cdot AR(7) - 3,01 \cdot AR(8) +$ $-0,76 \cdot AR(9) - 0,03 \cdot AR(12) +$ $-1,44 \cdot MA(2) + 0,44MA(6)$	0,987	2,257
D_2	1	$+0,953 \cdot AR(1) - 2,50 \cdot AR(2) +$ $+1,23 \cdot AR(3) - 2,50 \cdot AR(4) +$ $-1,03 \cdot AR(6) - 1,32 \cdot AR(7) +$ $-1,23 \cdot AR(9) - 0,53 \cdot AR(11) +$ $-0,18 \cdot AR(13) - 0,98 \cdot MA(2)$	0,989	1,910

FONTE: A autora (2016).


O ajuste e a previsão para o conjunto de teste de cada série decomposta, a partir dos modelos definidos no quadro acima, podem ser constatadas na Figura 5.8, Figura 5.9 e Figura 5.10. O horizonte de previsão compreende a 67 anos, ao invés de ser colocado os anos de previsão no eixo horizontal optou-se em evidenciar a quantidade de anos das observações previstas.

FIGURA 5.8 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE A_2 DA SÉRIE DE MANCHAS SOLARES




FONTE: A autora (2016).

FIGURA 5.9 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_1 DA SÉRIE DE MANCHAS SOLARES



FONTE: A autora (2016).

FIGURA 5.10 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_2 DA SÉRIE DAS MANCHAS SOLARES



Os eixos não são indicados pelo fato dos dados serem as decomposições dos dados originais, sendo assim podem apresentar valores negativos, ocasionando a perda de significado quantitativo.

A previsão a partir de uma determinada quantidade de observações, tende a um valor estável a medida que a quantidade de dados do horizonte de tempo é alcançado. Essa característica é destacada nas séries decompostas das Manchas solares a partir de aproximadamente 21 anos.

O modelo definido nesta etapa é utilizado na metodologia proposta 1 e 2, ressaltando que, a partir dessa fase que as metodologias se diferenciam.

5.2.1 Metodologia 1 aplicada a série das Manchas Solares

A fase subsequente da modelagem ARIMA das decomposições, na metodologia 1, é a combinação destas por meio dos ajustes do conjunto de treinamento. A equação (5.4) expressa a combinação definida.

$$\hat{y}_{CWA,t} = 0,9981\hat{A}_2 + 1,0421\hat{D}_1 + 1,0210\hat{D}_2 \quad (5.4)$$

A previsão e o ajuste do conjunto de teste é realizada, a junção dessas informações é realizada conforme a equação (5.4).

O cálculo dos resíduos da modelagem constitui a próxima fase da metodologia. Em seguida esses são decompostos utilizando a *Wavelet* Coif5 e modeladas pela RNA especificada no Quadro 5.7. Resaltando que a quantidade de elementos do padrão equivale a elementos das três séries de decomposição, exemplificando a RNA com previsão n passos a frente dos testes (Prev_RBF n) é composto por 7 elementos da série A_{2R} , 7 da série D_{1R} e 7 elementos da série D_{2R} , essa rede efetua a previsão dos 67 elementos do horizonte de previsão, sem qualquer tipo de informação do conjunto de teste.

QUADRO 5.7 - ESTRUTURA DA RNA DA METODOLOGIA 1 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DAS MANCHAS SOLARES

REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/CENTROIDES NA CAMADA OCULTA.	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
Aj_RBF1	3	11	1
Prev_RBF n	21	6	67

FONTE: A autora (2016).

Nesta fase os ajustes são combinados pela própria RNA, diferentemente do que ocorre com a combinação dos modelos ARIMA. Entretanto a combinação final $\hat{y}_{CWA,t}$ da modelagem ARIMA e das RNA são lineares, as equações (5.5) e (5.6) revelam as expressões que foram determinadas por meio do conjunto de treinamento.


$$\hat{y}_{CWAN1,Est.RBF_1} = 0,995\hat{y}_{CWA,t} + 1,049\hat{e}_{t,Est.RBF} \quad (5.5)$$

$$\hat{y}_{CWAN1,Din.RBF_n} = 1,000\hat{y}_{CWA,t} - 0,224\hat{e}_{t,Din.RBF_n} \quad (5.6)$$

Pode-se averiguar que os pesos da combinação Prev_RBF n , tem uma característica distinta das demais em relação a influência dos resíduos na composição da previsão final, sendo que as previsões dos resíduos, que utilizam Prev_RBF1, possuem praticamente a mesma influência na previsão final.

A Figura 5.11 contém as previsões referentes ao conjunto de teste aplicados aos modelos supracitados.

FIGURA 5.11 - PREVISÃO DO CONJUNTO DE TESTE DA METODOLOGIA 1 DA SÉRIE DAS MANCHAS SOLARES



FONTE: A autora (2016).

Constata-se a partir da Figura 5.11 que a previsão dos dados possuem o mesmo comportamento em relação aos modelos de previsão até os 6 primeiros anos do horizonte de previsão. Após aproximadamente seis anos a previsão n passos a frente começa a se distanciar das previsões um passo a frente e consequentemente da serie original. As previsões um passo a frente apresenta um excelente ajuste em relação a série original.

5.2.2 Metodologia 2 aplicada a série das Manchas Solares

Os resíduos de cada modelagem ARIMA referentes as decomposições *Wavelet* são calculados para o prosseguimento da metodologia 2.

A modelagem por meio de RNA é realizada para cada série de resíduos, a estrutura desta é definida pelo conjunto de treinamento e apresentada no Quadro 5.8.

QUADRO 5.8 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DAS MANCHAS SOLARES

COMPONENTE DE DECOMPOSIÇÃO	REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/ CENTROIDES NA CAMADA OCULTA.	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
A_{2R}	Aj_RBF1	5	16	1
	Prev_RBF1	6	25	1
	Prev_RBFn	6	6	67
D_{1R}	Aj_RBF1	4	13	1
	Prev_RBF1	6	21	1
	Prev_RBFn	6	7	67
D_{2R}	Aj_RBF1	4	21	1
	Prev_RBF1	6	16	1
	Prev_RBFn	6	5	67

FONTE: A autora (2016).

As estruturas das RNAs apresentadas anteriormente são aplicadas ao conjunto de teste gerando ajustes, previsões um passo e n passos a frente conforme a indicação do Quadro 5.8.

As combinações das previsões definidas pelo conjunto de treinamento são apresentadas no Quadro 5.9, elas são aplicadas ao conjunto de teste para a verificação da capacidade de generalização do modelo.

QUADRO 5.9 - MODELOS DE PREVISÃO DA METODOLOGIA 2 PARA A SÉRIE DAS MANCHAS SOLARES


REDE NEURAL	QUANTIDADE DE PESOS NA COMBINAÇÃO	MODELO
Aj_RBF1	6	$\hat{y}_{CWAN2} = 0,998\hat{A}_2 + 1,154\hat{A}_{2R} + 1,025\hat{D}_1 + 1,296\hat{D}_{1R} + 0,992\hat{D}_2 + 0,850\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 0,998\hat{A}_2 + \hat{A}_{2R} + 1,026\hat{D}_1 + \hat{D}_{1R} + 0,994\hat{D}_2 + \hat{D}_{2R}$
Prev_RBF1	6	$\hat{y}_{CWAN2} = 0,998\hat{A}_2 + 1,021\hat{A}_{2R} + 1,049\hat{D}_1 + 1,240\hat{D}_{1R} + 0,998\hat{D}_2 + 0,950\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 0,998\hat{A}_2 + \hat{A}_{2R} + 1,047\hat{D}_1 + \hat{D}_{1R} + 0,999\hat{D}_2 + \hat{D}_{2R}$
Prev_RBFn	6	$\hat{y}_{CWAN2} = 0,996\hat{A}_2 + 1,031\hat{A}_{2R} + 1,048\hat{D}_1 + 1,157\hat{D}_{1R} + 1,033\hat{D}_2 + 2,100\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 0,997\hat{A}_2 + \hat{A}_{2R} + 1,049\hat{D}_1 + \hat{D}_{1R} + 1,023\hat{D}_2 + \hat{D}_{2R}$

FONTE: A autora (2016).

Os valores dos coeficientes dos modelos de combinação podem ser considerados de um modo geral aproximadamente 1, tanto para o ajuste quanto para as previsões; a única exceção é constatada no coeficiente da previsão Prev_RBFn do resíduo, referente a componente de detalhe 2 (\hat{D}_{2R}) em relação as combinações com 6 pesos.


A Figura 5.12 e a Figura 5.13 apresentam as previsões concernentes ao conjunto de teste da série analisada.

FIGURA 5.12 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DAS MANCHAS SOLARES



FONTE: A autora (2016).

FIGURA 5.13 - PREVISÃO N PASSOS A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DAS MANCHAS SOLARES




FONTE: A autora (2016).

A previsão realizada pela Prev_RBFn tanto em relação a metodologia 1 como na metodologia 2, revela boa generalização em aproximadamente 10 anos, a partir desse marco tende-se a um valor estável para valores futuros.

Os trabalhos base da metodologia híbrida aqui desenvolvida indicam a estrutura AR(9) para a modelagem e previsão da série de Manchas Solares. A Figura 5.14 apresenta o ajuste do modelo ao teste Aj_AR(9) e a previsão Prev_AR(9) da estrutura citada.

FIGURA 5.14 - PREVISÕES AR(9) DO CONJUNTO DE TESTE DAS MANCHAS SOLARES



FONTE: A autora (2016).

Pode-se verificar também para a modelagem Box e Jenkins a diferença entre o ajuste e a previsão. Esse fato só ocorre no conjunto de teste.

Especificamente a Tabela 5.2 apresenta as métricas estatísticas, adotadas para a verificação da qualidade da previsão dos dados da série que fazem parte do horizonte de previsão.

TABELA 5.2 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DAS MANCHAS SOLARES

METODOLOGIA	MSE	MAE	RMSE
CWAN1_Aj_RBF1	5,933	1,868	2,436
CWAN1_Prev_RBFn	2454,206	34,41	49,540
CWAN2_Aj_RBF1_6P	3,287	1,401	1,813
CWAN2_Aj_RBF1_3P	3,637	1,493	1,907
CWAN2_Aj_RBF1_Soma	3,561	1,462	1,887
CWAN2_Prev_RBF1_6P	204,991	10,361	14,318
CWAN2_Prev_RBF1_3P	206,597	10,380	14,373
CWAN2_Prev_RBF1_Soma	206,609	10,373	14,374
CWAN2_Prev_RBFn_6P	2443,926	34,325	49,436
CWAN2_Prev_RBFn_3P	2442,434	34,320	49,421
CWAN2_Prev_RBFn_Soma	2435,424	34,285	49,350
Aj_AR(9)	306,082	13,033	-
Prev_AR(9)	3186,404	37,745	56,448
RNA-MLP	351,193	13,544	-
Zhang (2003)	280,159	12,780	-
Khashei; Bijari (2011)	218,642	11,447	-
Gan; Peng; Dong (2012)	160,642	-	-
Adhikari; Agrawal (2014)	1479,64	-	-

FONTE: A autora (2016).

Pode-se constatar pelos valores acima que existe uma diferença expressiva entre os ajustes e as previsões um passo e n passos a frente, sendo que as previsões n passos a frente tanto da metodologia 1 e 2 não se sobressaem em relação aos métodos da literatura. A previsão 1 passo a frente obtém o valor do MAE melhor que os métodos apresentados na literatura.

5.3 METODOLOGIAS PROPOSTAS APLICADAS A SÉRIE DA TAXA DE CÂMBIO

A *Wavelet* Sym6 foi utilizada para decompor a série temporal da Taxa de Câmbio, gerando três séries de decomposição. A série original foi suavizada pelo logaritmo antes de ser decomposta, para tornar possível a comparação das metodologias propostas com trabalhos da literatura.

O conjunto de treinamento, referente a cada série decomposta, é modelado pelo método ARIMA, a estrutura de cada modelo é retratado no Quadro 5.10.

QUADRO 5.10 - MODELO ARIMA DAS COMPONENTES *WAVELET* DA SÉRIE DA TAXA DE CÂMBIO


COMPONENTES <i>WAVELET</i>	NÚMERO DE DIFERENCIAÇÕES	MODELO ARIMA	R^2	<i>DURBIN- WATSON</i>
A_2	1	$0,27 \cdot AR(1) + 0,16 \cdot AR(2) +$ $+0,29 \cdot AR(3) - 0,74 \cdot AR(4) +$ $+0,27 \cdot AR(5) - 0,33 \cdot AR(8) +$ $+2,91 \cdot MA(1) - 3,77 \cdot MA(2) +$ $+3,74 \cdot MA(3) + 2,83 \cdot MA(4) +$ $+0,94 \cdot MA(5)$	0,990	1,960
D_1	0	$+1,46 \cdot AR(1) - 2,51 \cdot AR(2) +$ $+2,25 \cdot AR(3) - 2,15 \cdot AR(4) +$ $+1,00 \cdot AR(5) - 0,60 \cdot AR(6) +$ $-0,05 \cdot AR(7) - 2,13 \cdot MA(2) +$ $+0,58 \cdot MA(4) - 1,29 \cdot MA(6) +$ $-0,73 \cdot MA(8)$	0,991	1,865
D_2	0	$-3,29 \cdot AR(1) - 7,59 \cdot AR(2) +$ $-14,03 \cdot AR(3) - 21,45 \cdot AR(4) +$ $-29,10 \cdot AR(5) - 35,53 \cdot AR(6) +$ $-39,87 \cdot AR(7) - 41,49 \cdot AR(8) +$ $-40,28 \cdot AR(9) - 36,48 \cdot AR(10) +$ $-30,74 \cdot AR(11) - 23,97 \cdot AR(12) +$ $-17,05 \cdot AR(13) - 10,90 \cdot AR(14) +$ $-6,08 \cdot AR(15) - 2,81 \cdot AR(16) +$ $-1,02 \cdot AR(17) - 0,22 \cdot AR(18) +$ $-0,99 \cdot MA(4)$	0,965	2,097

FONTE: A autora (2016).

Os modelos apresentam valores de R^2 aproximadamente 1, que é o valor desejável; o valor para o teste de Durbin-Watson também revelam uma boa modelagem, pois são próximos de 2. Esses modelos são utilizados para ajustar e prever os valores futuros do conjunto de teste.


As previsões para o conjunto de teste, com o horizonte de tempo de 52 semanas são apresentadas na Figura 5.15, Figura 5.16 e Figura 5.17.

FIGURA 5.15 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE A_2 DA SÉRIE DA TAXA DE CâMBIO




FONTE: A autora (2016).

FIGURA 5.16 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_1 DA SÉRIE DA TAXA DE CâMBIO



FONTE: A autora (2016).

FIGURA 5.17 - PREVISÕES DO CONJUNTO DE TESTE DA COMPONENTE D_2 DA SÉRIE DA TAXA DE CâMBIO



FONTE: A autora (2016).

O comportamento do ajuste e previsão, como nas demais séries já analisadas, apresentam diferenças de precisão. Quando maior o horizonte de previsão maior será a distinção entre elas e mais evidente a tendência da previsão.

5.3.1 Metodologia 1 aplicada a série da Taxa de Câmbio

A combinação das modelagens ARIMA citadas na seção anterior é definida pela equação (5.7).

$$\hat{y}_{CWA,t} = 0,9998\hat{A}_2 + 1,0000\hat{D}_1 + 1,0000\hat{D}_2 \quad (5.7)$$

Verifica-se que a combinação é praticamente a soma das previsões do modelo ARIMA.

O resíduo da previsão combinada é calculado, a próxima etapa é a decomposição utilizando a *Wavelet* Coif5. As séries geradas pela decomposição são combinadas por meio da RNA, ou seja, compõem o padrão de entrada da rede. A estrutura de cada RNA é apresentada no Quadro 5.11.

QUADRO 5.11 - ESTRUTURA DA RNA DA METODOLOGIA 1 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DA TAXA DE CÂMBIO

REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/CENTROIDES NA CAMADA OCULTA.	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
Aj_RBF1	3	28	1
Prev_RBFn	12	49	52

FONTE: A autora (2016).

A quantidade de 28 centroides referente a Aj_RBF1 equivale a 3% dos padrões formados, em relação a Prev_RBFn, 49 centroides equivale a 8% dos padrões da rede neural. As redes efetuam o ajuste e a previsão n passos a frente considerando o horizonte de previsão de 52 semanas.

A previsão final que combina a modelagem ARIMA e a RNA é definida especificamente conforme a rede neural utilizada, que são respectivamente apresentadas nas equações (5.8), (5.9) e (5.10).


$$\hat{y}_{CWAN1,Est.MLP} = \hat{y}_{CWA,t} + \hat{e}_{t,Est.MLP} \quad (5.8)$$

$$\hat{y}_{CWAN1,Est.RBF_1} = \hat{y}_{CWA,t} + \hat{e}_{t,Est.RBF} \quad (5.9)$$

$$\hat{y}_{CWAN1,Din.RBF_n} = 1,003\hat{y}_{CWA,t} + 1,000\hat{e}_{t,Din.RBF_n} \quad (5.10)$$

A combinação linear pode ser considerada como a soma das previsões, isso pode ser observado por intermédio dos coeficientes das equações acima. Após definido o modelo final, este é aplicado ao conjunto de teste, o resultado pode ser averiguado na Figura 5.18.

FIGURA 5.18 - PREVISÃO DO CONJUNTO DE TESTE DA METODOLOGIA 1 DA SÉRIE DA TAXA DE CâMBIO



FONTE: A autora (2016).

A Figura 5.18 evidencia a notória discrepância entre o ajuste e a previsão em relação ao conjunto de teste da série da Taxa de Câmbio; apenas aproximadamente as quatro primeiras semanas utilizando a RNA RBF_n obtiveram uma previsão satisfatória.

5.3.2 Metodologia 2 aplicada a série da Taxa de Câmbio

A continuação da metodologia 2 é proporcionada pelo cálculo do resíduo das modelagens ARIMA, que são a base das duas metodologias desenvolvidas.

Os resíduos de cada série são modelados pela RNA, a fim de captar autodependência não linear dos dados, a estrutura das redes é exposta no Quadro 5.12.

QUADRO 5.12 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE DA TAXA DE CÂMBIO

COMPONENTE DE DECOMPOSIÇÃO	REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/ CENTROIDES NA CAMADA OCULTA.	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
A_{2R}	Aj_RBF1	7	35	1
	Prev_RBF1	4	31	1
	Prev_RBFn	6	25	52
D_{1R}	Aj_RBF1	7	35	1
	Prev_RBF1	5	43	1
	Prev_RBFn	4	19	52
D_{2R}	Aj_RBF1	7	71	1
	Prev_RBF1	4	43	1
	Prev_RBFn	4	19	52

FONTE: A autora (2016).

A quantidade de centroides, como indicado na literatura, não ultrapassam de 10% dos padrões, espera-se com isso evitar um excelente ajuste do conjunto de treinamento e uma generalização ruim para o conjunto de teste. A quantidade de centroides especificamente para esta série está entre 3% e 10%.

As RNAs definidas no Quadro 5.12 são extrapolados para o conjunto de teste, conforme a indicação do tipo de previsão.

As previsões obtidas para o conjunto de treinamento são combinadas, essas combinações são apresentadas no Quadro 5.13.

QUADRO 5.13 - MODELOS DE PREVISÃO DA METODOLOGIA 2 PARA A SÉRIE DE TAXA DE CÂMBIO

REDE NEURAL	QUANTIDADE DE PESOS NA COMBINAÇÃO	MODELO
Aj_RBF1	6	$\hat{y}_{CWAN2} = \hat{A}_2 + \hat{A}_{2R} + \hat{D}_1 + \hat{D}_{1R} + \hat{D}_2 + \hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = \hat{A}_2 + \hat{A}_{2R} + \hat{D}_1 + \hat{D}_{1R} + \hat{D}_2 + \hat{D}_{2R}$
Prev_RBF1	6	$\hat{y}_{CWAN2} = \hat{A}_2 + \hat{A}_{2R} + \hat{D}_1 + \hat{D}_{1R} + \hat{D}_2 + \hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = \hat{A}_2 + \hat{A}_{2R} + \hat{D}_1 + \hat{D}_{1R} + \hat{D}_2 + \hat{D}_{2R}$
Prev_RBFn	6	$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + 0,066\hat{A}_{2R} + 1,014\hat{D}_1 + 0,957\hat{D}_{1R} + 1,031\hat{D}_2 + 0,994\hat{D}_{2R}$
	3	$\hat{y}_{CWAN2} = 1,009\hat{A}_2 + \hat{A}_{2R} + 1,000\hat{D}_1 + \hat{D}_{1R} + 1,000\hat{D}_2 + \hat{D}_{2R}$

FONTE: A autora (2016).

Os coeficientes da combinação referente a Prev_RBF1, tanto para a configuração de 6 e 3 pesos, possuem valores de aproximadamente 1, essa


diferença se inicia a partir da terceira casa decimal. Os coeficientes estão sendo apresentados apenas com três casas decimais, em virtude do arredondamento empregado os coeficientes são representados com o valor 1.

A única combinação que obteve coeficientes 1, foi a configuração do Aj_RBF1, esse fato pode ser constatado por meio do QUADRO 5.13; o quadro citado possui os resultados estatísticos para o conjunto de teste.

Verifica-se que para o caso da Prev_RBFn, os coeficientes relacionados a modelagem dos resíduos, principalmente ao resíduo de \hat{A}_{2R} , possui sua influência reduzida na composição do modelo final.

As previsões referentes ao conjunto de teste da série analisada é apresentada na Figura 5.19 e na Figura 5.20. Os ajustes não são representados nas figuras pelo fato de seu ajuste resultar praticamente na série original, inviabilizando a observação.


FIGURA 5.19 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DA TAXA DE CÂMBIO



FONTE: A autora (2016).

A generalização do conjunto de teste, no horizonte de previsão de 52 semanas, realizada pela metodologia 2 empregando a Prev_RBF1 é interessante. De modo geral a metodologia capta o comportamento da série original, como pode ser observado na Figura 5.19.

FIGURA 5.20 - PREVISÃO N PASSOS A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE DA TAXA DE CÂMBIO



FONTE: A autora (2016).

As quatro primeiras semanas do horizonte de tempo são previstas satisfatoriamente, considerando a Prev_RBFn aplicada a metodologia 2, a previsão a partir da semana citada começa a se distanciar dos dados originais, tendendo a um valor constante.

A constatação da precisão de cada modelo pode ser realizada a partir da observação da Tabela 5.3.

TABELA 5.3 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DA TAXA DE CÂMBIO

METODOLOGIA	MSE	MAE	RMSE
CWAN1_Aj_RBF ₁	1,500 x10⁻⁷	2,980 x10⁻⁴	3,873 x10⁻⁴
CWAN1_Prev_RBF _n	1,262 x10 ⁻⁴	9,096 x10 ⁻³	1,123 x10 ⁻²
CWAN2_Aj_RBF_6P	2,844 x10⁻⁷	4,041 x10⁻⁴	5,333 x10⁻⁴
CWAN2_Aj_RBF ₁ _3P	2,844 x10⁻⁷	4,041 x10⁻⁴	5,333 x10⁻⁴
CWAN2_Aj_RBF ₁ _Soma	2,844 x10⁻⁷	4,041 x10⁻⁴	5,333 x10⁻⁴
CWAN2_Prev_RBF ₁ _6P	1,944 x10⁻⁶	1,033 x10⁻³	1,394 x10⁻³
CWAN2_Prev_RBF ₁ _3P	1,943 x10⁻⁶	1,033 x10⁻³	1,394 x10⁻³
CWAN2_Prev_RBF ₁ _Soma	1,948 x10⁻⁶	1,032 x10⁻³	1,396 x10⁻³
CWAN2_Prev_RBF _n _6P	1,275 x10 ⁻⁴	9,177 x10 ⁻³	1,129 x10 ⁻²
CWAN2_Prev_RBF _n _3P	1,223 x10 ⁻⁴	8,944 x10 ⁻³	1,106 x10 ⁻²
CWAN2_Prev_RBF _n _Soma	1,047 x10 ⁻⁴	8,284 x10 ⁻³	1,023 x10 ⁻²
<i>Random Walk</i>	4,529 x10 ⁻⁵	5,358 x10 ⁻³	-
RNA-MLP	4,526 x10 ⁻⁵	5,251 x10 ⁻³	-
Zhang (2003)	4,360 x10 ⁻⁵	5,121 x10 ⁻³	-
Khashei; Bijari (2011)	3,648 x10 ⁻⁵	4,970 x10 ⁻³	-

FONTE: A autora (2016).

Ressaltando que as previsões realizadas com a utilização do Aj_RBF1 são na verdade a soma dos ajustes de cada fase. Os coeficientes da combinação das demais metodologias 2 são aproximadamente 1, por esta razão a diferença entre o resultado das estatísticas são iguais ou aproximadamente iguais.

As previsões, com exceção da CWAN2_Prev_RBF_n, possuem um aumento de precisão em relação aos modelos clássicos ARIMA e RNA-MLP, e dos híbridos base desse estudo.

5.4 METODOLOGIA PROPOSTA APLICADA A SÉRIE DO PIEZOMETRO PS-F-72

A série do piezômetro PS-F-72 é não estacionária, ela não se desenvolve ao redor de uma média e variância constante, ou seja, suas características se alteram ao longo do tempo. Por esta razão o modelo ARIMA é utilizado para contornar esta característica da série. Entretanto a aplicação da rede neural também é capaz de lidar com este comportamento não estacionário.

Primeiramente foi realizada a DW de nível igual a 2 da série do piezômetro, utilizando a *Wavelet* Db45, obteve-se uma componente de aproximação A e duas componentes de detalhes D_1 e D_2 .

As séries da decomposição são ajustadas ao modelo ARIMA, sua estrutura é apresentada no Quadro 5.14.

QUADRO 5.14 - MODELO ARIMA DAS COMPONENTES WAVELET DA SÉRIE PS-F-72

COMPONENTES WAVELET	NÚMERO DE DIFERENCIAÇÕES	MODELO ARIMA	R^2	DURBIN-WATSON
A_2	1	$5,87 \cdot AR(1) - 15,70 \cdot AR(2) +$ $+24,62 \cdot AR(3) - 24,44 \cdot AR(4) +$ $+15,35 \cdot AR(5) - 5,65 \cdot AR(6) +$ $0,95 \cdot AR(7) + 2,85 \cdot MA(1) +$ $+2,42 \cdot MA(2) + 0,14 \cdot MA(3) +$ $-0,75 \cdot MA(4) - 0,80 \cdot MA(5) +$ $-0,74 \cdot MA(6) - 0,27 \cdot MA(7)$	1,000	1,092
D_1	1	$-0,86 \cdot AR(1) - 0,63 \cdot AR(2) +$ $+0,22 \cdot AR(4) + 0,12 \cdot AR(8) +$ $-1,97 MA(1) + 0,96 \cdot MA(2)$	0,961	2,800
D_2	0	$0,82 \cdot AR(1) - 1,03 \cdot AR(2) +$ $+0,27 \cdot AR(3) + 1,20 \cdot MA(1) +$ $0,20 \cdot MA(6)$	0,947	1,447

FONTE: A autora (2016).

As modelagens, embora tenham um valor de R^2 aproximadamente 1, apresentam Durbin-Watson abaixo ou acima de 2, o que configura um ajuste com precisão menor. Ressaltando que a série é composta de 346 dados mensais, o conjunto de treinamento adotado para a modelagem ARIMA é composto por 322 dados e o conjunto de teste, utilizado para fazer a previsão, contém 24 dados, o equivalente a 2 anos.

Optou-se por fazer apenas a metodologia 2 e ainda utilizar a previsão dos resíduos por meio da Prev_RBF1, essa escolha foi baseada na análise dos resultados da aplicação de ambas as metodologias para as séries apresentadas anteriormente.

A modelagem ARIMA é empregada para fazer a previsão do conjunto de teste. O resíduo dessa modelagem é calculado, dando prosseguimento a

metodologia, os resíduos de cada série de decomposição são modelados pela Prev_RBF1.

A estrutura da RBF em relação a cada série de resíduos é exposto no Quadro 5.15.

QUADRO 5.15 - ESTRUTURA DA RNA DA METODOLOGIA 2 PARA A MODELAGEM DOS RESÍDUOS DA SÉRIE PS-F-72

COMPONENTE DE DECOMPOSIÇÃO	REDE NEURAL	QUANTIDADE de ELEMENTOS no PADRÃO de ENTRADA	QUANTIDADE DE NEURÔNIOS/ CENTROIDES NA CAMADA OCULTA.	QUANTIDADE DE ELEMENTOS NO PADRÃO DE SAÍDA
A_{2R}	Prev_RBF1	5	9	1
D_{1R}		4	26	1
D_{2R}		4	23	1

FONTE: A autora (2016).

A metodologia 2 faz a combinação dos resíduos de três maneiras diferentes, a primeira é atribuindo pesos a todas as previsões (equação (5.11)); a segunda atribuindo pesos apenas a previsão das decomposições (equação (5.12)), os resíduos nesse caso são apenas somados as demais previsões; a última configuração é a soma das previsões.


$$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + 1,000\hat{A}_{2R} + 1,007\hat{D}_1 + 1,007\hat{D}_{1R} + 0,983\hat{D}_2 + 0,998\hat{D}_{2R} \quad (5.11)$$

$$\hat{y}_{CWAN2} = 1,000\hat{A}_2 + \hat{A}_{2R} + 1,007\hat{D}_1 + \hat{D}_{1R} + 0,984\hat{D}_2 + \hat{D}_{2R} \quad (5.12)$$

Os pesos, coeficientes da combinação, são aproximadamente 1, ou seja a previsão gerada por essas configurações são praticamente as mesmas, este fato pode ser verificado na Figura 5.22, a figura apresenta as previsões do conjunto de teste utilizando a metodologia 2.

A Figura 5.21 expõe as previsões dos modelos clássicos da literatura, o modelo AR(1) e a RNA-RBF; o modelo ARIMA não obteve bom ajuste aos dados de treino (dentro da amostra).


FIGURA 5.21 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA SÉRIE PS-F-72 PARA MODELOS CLÁSSICOS



FONTE: A autora (2016).

A partir do gráfico acima pode-se verificar que a previsão do conjunto de teste em relação aos modelos clássicos não obtiveram um ajuste satisfatório. Isso pode ser confirmado por meio da Tabela 5.4, que apontam os valores estatísticos das previsões aplicadas a série temporal do piezômetro PS-F-72.

FIGURA 5.22 - PREVISÃO UM PASSO A FRENTE DO CONJUNTO DE TESTE DA METODOLOGIA 2 DA SÉRIE PS-F-72



FONTE: A autora (2016).

A diferença entre as configurações da metodologia 2 proposta, graficamente não é perceptível, estatisticamente é percebida a partir da terceira casa decimal apenas. A precisão da metodologia mostra-se promissora em comparação aos modelos clássicos.

TABELA 5.4 - ESTATÍSTICA DA METODOLOGIA APLICADA AO CONJUNTO DE TESTE DA SÉRIE DO PIEZÔMETRO PS-F-72

METODOLOGIA	MSE	MAE	RMSE
CWAN2_Prev_RBF ₁ _6P	0,0860	0,7621	0,2933
CWAN2_Prev_RBF ₁ _3P	0,0859	0,2412	0,2931
CWAN2_Prev_RBF ₁ _Soma	0,0866	0,2419	0,2943
ARIMA	7,4952	2,4570	2,7377
RNA Prev_RBF	1,0131	0,7621	1,0065

FONTE: A autora (2016).

A previsão da RNA-RBF é superior a realizada por meio da modelagem ARIMA, neste caso o AR(1), mas o modelo proposto supera a RNA-RBF. Salienta-se que a configuração da combinação da metodologia neste caso, não altera de forma significativa a previsão da série temporal.

A Tabela 5.5 resume todos os melhores resultados obtidos em relação as metodologias propostas.

TABELA 5.5 - MELHORES RESULTADOS DE PREVISÃO PARA AS SÉRIES ESTUDADAS

SÉRIE LINES CANADENSES			
METODOLOGIA	MSE	MAE	RMSE
CWAN1_Aj_RBF1	1,391 x10⁻⁴	1,028 x10⁻²	1,179 x10⁻¹
CWAN2_Aj_RBF1_6P	7,247 x10⁻⁵	6,658 x10⁻³	8,513 x10⁻³
CWAN2_Aj_RBF1_3P	5,387 x10⁻⁵	5,334 x10⁻³	7,340 x10⁻³
CWAN2_Aj_RBF1_Soma	4,869 x10⁻⁵	5,305 x10⁻³	6,978 x10⁻³
Aj_AR(12)	3,207x10 ⁻²	1,404 x10 ⁻¹	1,791 x10 ⁻¹
Prev_AR(12)	3,592 x10 ⁻¹	5,232 x10 ⁻¹	5,993 x10 ⁻¹
RNA-MLP	2,046 x10 ⁻²	1,121 x10 ⁻¹	-
Zhang (2003)	1,723 x10 ⁻²	1,040 x10 ⁻¹	-
Aladag et al. (2009)	9,000 x10 ⁻³	-	-
Zheng; Zhong (2011)	-	-	4,69 x10 ⁻²
Khashei; Bijari (2011)	9,900 x10 ⁻³	8,506 x10 ⁻²	-
Adhikari; Agrawal (2014)	1,15 x10 ⁻²	-	--

(Continua)

(continuação)

SÉRIE DAS MANCHAS SOLARES

METODOLOGIA	MSE	MAE	RMSE
CWAN1_Aj_RBF1	5,933	1,868	2,436
CWAN2_Aj_RBF1_6P	3,287	1,401	1,813
CWAN2_Aj_RBF1_3P	3,637	1,493	1,907
CWAN2_Aj_RBF1_Soma	3,561	1,462	1,887
CWAN2_Prev_RBF1_6P	204,991	10,361	14,318
CWAN2_Prev_RBF1_3P	206,597	10,380	14,373
CWAN2_Prev_RBF1_Soma	206,609	10,373	14,374
Aj_AR(9)	306,082	13,033	-
Prev_AR(9)	3186,404	37,745	56,448
RNA-MLP	351,193	13,544	-
Zhang (2003)	280,159	12,780	-
Khashei; Bijari (2011)	218,642	11,447	-
Gan; Peng; Dong (2012)	160,642	-	-
Adhikari; Agrawal (2014)	1479,64	-	-

SÉRIE DA TAXA DE CÂMBIO

CWAN1_Aj_RBF ₁	1,500 x10⁻⁷	2,980 x10⁻⁴	3,873 x10⁻⁴
CWAN2_Aj_RBF _{1_6P}	2,844 x10⁻⁷	4,041 x10⁻⁴	5,333 x10⁻⁴
CWAN2_Aj_RBF _{1_3P}	2,844 x10⁻⁷	4,041 x10⁻⁴	5,333 x10⁻⁴
CWAN2_Aj_RBF _{1_Soma}	2,844 x10⁻⁷	4,041 x10⁻⁴	5,333 x10⁻⁴
CWAN2_Prev_RBF _{1_6P}	1,944 x10⁻⁶	1,033 x10⁻³	1,394 x10⁻³
CWAN2_Prev_RBF _{1_3P}	1,943 x10⁻⁶	1,033 x10⁻³	1,394 x10⁻³
CWAN2_Prev_RBF _{1_Soma}	1,948 x10⁻⁶	1,032 x10⁻³	1,396 x10⁻³
<i>Random Walk</i>	4,529 x10 ⁻⁵	5,358 x10 ⁻³	-
RNA-MLP	4,526 x10 ⁻⁵	5,251 x10 ⁻³	-
Zhang (2003)	4,360 x10 ⁻⁵	5,121 x10 ⁻³	-
Khashei; Bijari (2011)	3,648 x10 ⁻⁵	4,970 x10 ⁻³	-

SÉRIE DO PIEZÔMETRO PS-F-72

CWAN2_Prev_RBF _{1_6P}	0,0860	0,7621	0,2933
CWAN2_Prev_RBF _{1_3P}	0,0859	0,2412	0,2931
CWAN2_Prev_RBF _{1_Soma}	0,0866	0,2419	0,2943
ARIMA	7,4952	2,4570	2,7377
RNA Prev_RBF	1,0131	0,7621	1,0065

6 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Trabalhos de desenvolvimento de modelos híbridos estão se tornando foco em previsões de séries temporais, isso é notado pela crescente quantidade de artigos publicados.

Métodos já consagrados, em previsões de séries temporais da literatura, são aplicados conjuntamente a fim de se usufruir especificamente de cada característica das técnicas.

Nesta tese foi apresentada duas metodologias híbridas, compostas por ARIMA e RNA-RBF, essas buscam explorar o potencial de cada técnica de previsão e de decomposição dos dados da série. A decomposição *Wavelet* é empregada com o objetivo de suavizar as séries, separando-a em séries distintas que possuem características semelhantes.

Foram realizados ajustes e previsões um passo a frente e n passos a frente em relação a ambas as metodologias propostas, para as séries dos Linces Canadenses, das Manchas Solares e da Taxa de Câmbio.

Foi realizada uma breve investigação com relação ao tipo de *Wavelet* a ser empregada, em trabalhos preliminares a *Wavelet* Haar foi empregada a todas as séries em estudo. Após essa fase verificou-se que outras *Wavelets* eram utilizadas na literatura, então foi desenvolvido uma metodologia simples para identificar o tipo de *Wavelet* mais apropriada a cada série. A escolha do melhor tipo de *Wavelet* foi baseada no menor desvio dentro os maiores desvios calculados entre a série de componentes de aproximação e a série de dados original. A componente de aproximação foi utilizada por ser a que mais influencia na previsão. Essa modificação gerou um ganho preditivo a série temporal.

O ajuste das metodologia propostas tiveram uma precisão maior as da literatura, considerando essas séries especificamente; ressaltando que ele utiliza o próprio valor do conjunto de teste e não da previsão realizada para fazer as próximas previsões.

O erro MSE do ajuste da série dos Linces Canadenses, utilizando a metodologia proposta, é de $4,869 \times 10^{-5}$ considerando CWAN2_Aj_Rbf1_Soma enquanto que na literatura o menor erro foi de $9,900 \times 10^{-3}$. A série das Manchas Solares obteve um MSE de ajuste de 3,287 para a CWAN2_Aj_RBF1_6p e de

previsão 204,991 para a CWAN2_Prev_RBF1_6p, entretanto, o erro de ajuste da literatura é de 160,642. O erro MSE para a metodologia aplicada a série da Taxa de Câmbio foi de $1,500 \times 10^{-7}$ para CWAN1_Aj_RBF1 e de $1,943 \times 10^{-6}$ para CWAN2_Prev_RBF1_3p, erro determinado pela literatura é de $3,648 \times 10^{-5}$.

O fato da previsão n passos a frente obter uma precisão menor se comparado a previsão um passo a frente, também foi observado por Babu; Reddy (2014). A metodologia 2 que emprega a Prev_RBF1 um passo a frente, na maioria das aplicações as séries da literatura, obteve precisão próxima ou superior aos modelos clássicos e aos métodos híbridos da literatura.

A previsão um passo a frente possui a informação das previsões dos elementos do conjunto de teste, isso de certa forma provê uma melhora na precisão, mesmo que essas possuam erros intrínsecos. A previsão n passos a frente proposto neste estudo não recebe qualquer informação do conjunto de teste, pois são previstos de uma única vez, essa característica faz com que a previsão seja inferior a um passo a frente.

A aplicação da metodologia as séries da literatura, fez se necessária para verificação da precisão dos métodos propostos. Identificou-se que a metodologia 2 utilizando a previsão um passo a frente é a mais precisa, sendo assim ela foi aplicada a série temporal do piezômetro PS-F-72, instrumento que auxilia no monitoramento da barragem da Usina Hidrelétrica de Itaipu. O erro MSE obtido pela metodologia CWAN2_Prev_RBF1_3p é de 0,0859; enquanto que a modelagem ARIMA obteve 7,4952 e a RNA-RBF 1,0131.

A informação de previsões das series temporais, pode auxiliar na tomada de decisão por parte da equipe responsável pela segurança e monitoramento estrutural da barragem, tornando possível o planejamento antecipado de ações corretivas e preventivas, até mesmo indicando prováveis épocas para que essas ações sejam realizadas. Poderia se estudar o caso da previsão ser incorporada à árvore de falhas da usina hidrelétrica.

Os parâmetros das metodologias propostas podem ser determinados por heurísticas ou metaheurísticas, isso provavelmente acarretará uma melhoria na metodologia.

Formas diferentes de combinações de previsões de séries temporais poderiam ser investigadas, outras técnicas de previsão lineares e não lineares poderiam também ser um foco de investigação.

Uma metodologia robusta para a escolha da *Wavelet* a ser adotada para decomposição poderia ser investigada e desenvolvida em trabalhos futuros, visto que o tipo de *Wavelet* influencia na modelagem e consequentemente na precisão do método. Este tema não é explorado de modo claro na literatura.

A investigação da influência da Decomposição *Wavelet* (DW) na definição dos parâmetros dos modelos que compõem a metodologia, sendo que em trabalhos pesquisados não é claro se a DW deve ser realizada a todo conjunto de dados ou apenas ao conjunto de treinamento.

7 REFERÊNCIAS

ADAMOWSKI, J.; CHAN, H. F. A wavelet neural network conjunction model for groundwater level forecasting. **Journal of Hydrology**, v. 407, n. 1-4, p. 28–40, 2011.

ADHIKARI, R.; AGRAWAL, R. K. A linear hybrid methodology for improving accuracy of time series forecasting. **Neural Computing and Applications**, v. 25, p. 269–281, 2014.

ALADAG, C. H.; EGRIOGLU, E.; KADILAR, C. Forecasting nonlinear time series with a hybrid methodology. **Applied Mathematics Letters**, v. 22, n. 9, p. 1467–1470, 2009.

ANSUJ, A. P.; CAMARGO, M.E.; RADHARAMANAN, R.; PETRY, D.G. Sales forecasting using time series and neural networks. **Computers & Industrial Engineering**, v.31, n 1/2, p. 421-424, 1996.

BABU, C. N.; REDDY, B. E. A moving-average filter based hybrid ARIMA–ANN model for forecasting time series data. **Applied Soft Computing**, v. 23, p. 27–38, 2014.

BARBOSA, A. C. B.; BLITZKOW, D. Ondaletas : Histórico e Aplicação. Disponível em: <http://sites.poli.usp.br/ptr/lgt/FTP/Apostila_Ondaletas_MSc.Augusto_Barbosa&Dr.Denizar_Blitzkow.pdf>.2008.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis**. 4^o ed. New Jersey: Wiley, 2008.

BRASIL. 12.334. **Lei de Segurança de Barragens**. 20 set. 2010.

BUKENYA, P.; MOYO, P.; BEUSHAUSEN, H.; OOSTHUIZEN, C. Health monitoring of concrete dams: A literature review. **Journal of Civil Structural Health Monitoring**, v. 4, n. 4, p. 235–244, 2014.

BUZZI, M. F.; SELL, A.; CHAVES, A. Leituras de Instrumentos de Monitoração Geotécnico-Estrutural e Temperatura Ambiente na Barragem de Itaipu - Caso do Pêndulo Direto. CMNE/CILAMCE. **Anais...**, 2007. Porto.

CASWELL, J. M. Combination of Wavelet Analysis and Artificial Neural Networks Applied to Forecast of Daily Cosmic Ray Impulses. **International Letters of Chemistry, Physics and Astronomy**, v. 15, p. 55–63, 2014.

CEASB. Centro de Estudos Avançados em Segurança de Barragens. Disponível em: <<http://www.pti.org.br/ceasb>>. Acesso em: 15/12/2015.

CHANG, W. An RBF neural network combined with OLS algorithm and genetic algorithm for short-term wind power forecasting. **Journal of Applied Mathematics**, v. 2013, p. 1–9, 2013.

CHAOVALIT, P.; GANGOPADHYAY, A.; KARABATIS, G.; CHEN, Z. Discrete wavelet transform-based time series analysis and mining. **ACM Computing Surveys**, v. 43, n. 2, p. 1–37, 2011.

COELHO, L., S.; SANTOS, A. A. P. A RBF neural network model with GARCH errors: Application to electricity price forecasting. **Electric Power Systems Research**, v. 81, n. 1, p. 74–83, 2011.

DANIEL, M. **Piezómetro tipo "Stand Pipe"**. Foz do Iguaçu: Itaipu Binacional, 2004. Relatório técnico Itaipu Binacional.

DAUBECHIES, I. Orthonormal bases of compactly supported wavelets. **Communications on Pure and Applied Mathematics**, v. 41, n. 7, p. 909–996, 1988.

DING, S.; MA, G.; SHI, Z. A Rough RBF Neural Network Based on Weighted Regularized Extreme Learning Machine. **Neural Processing Letters**, v. 40, n. 3, p. 245–260, 2013.

DING, S.; XU, X.; ZHU, H.; WANG, J.; JIN, F. Studies on Optimization Algorithms for Some Artificial Neural Networks Based on Genetic Algorithm (GA). **Journal of Computers**, v. 6, n. 5, p. 939–946, 2011.

DTI. **Diretoria Técnica de Itaipu. Usina Hidrelétrica de Itaipu Aspectos de Engenharia**. 2009.

FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. **Philosophical transactions. Series A, Mathematical, physical, and engineering sciences**, v. 365, n. December 2006, p. 303–315, 2007.

FAYAL, M. A. DE A. **Previsão de Vazão por Redes Neurais Artificiais e Transformada Wavelet**, 2008. Pontifícia Universidade Católica do Rio de Janeiro.

GAN, M.; PENG, H.; CHEN, L. A global–local optimization approach to parameter estimation of RBF-type models. **Information Sciences**, v. 197, p. 144–160, 2012.

GAN, M.; PENG, H.; DONG, X. A hybrid algorithm to optimize RBF network architecture and parameters for nonlinear time series prediction. **Applied Mathematical Modelling**, v. 36, n. 7, p. 2911–2919, 2012.

GUANG-YONG, X.; JIAN-PING, Y.; BAO-XING, Z.; PU, T. Application of an artificial immune algorithm on a statistical model of dam displacement. **Computers & Mathematics with Applications**, v. 62, n. 10, p. 3980–3986, 2011.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise Multivariada De Dados**. 6 ed ed. São Paulo: Bookman Companhia Editora Ltda, 2009.

HAYKIN, S. **Redes Neurais - Principios E Prática**. 2º ed. Porto Alegre:

Bookman, 2001.

HERRERA, L. J.; POMARES, H.; ROJAS, I.; ROJAS, I.; GUILLÉN, A.; RUBIO, G.; URQUIZA, J.; Global and local modelling in RBF networks. **Neurocomputing**, v. 74, n. 16, p. 2594–2602, 2011.

ICOLD. International Commission on Large Dams. Disponível em: <http://www.icold-cigb.org/GB/Dams/dams_safety.asp>. Acesso em: 2015.

JAFARIAN, Y.; HADDAD, A.; JAVDANIAN, H. Predictive Model for Normalized Shear Modulus of Cohesive soils. **Acta Geodyn**, 2014.

JIURIAN, H.; BINGFENG, S. The application of ARIMA-RBF model in urban rail traffic volume forecast. In: International Conference on Computer Science and Electronics Engineering, 2, 2013. **Proceedings...** Paris: Atlantis Press, 2013. p.1662–1665.

KHASHEI, M.; BIJARI, M. A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. **Applied Soft Computing**, v. 11, n. 2, p. 2664–2675, 2011.

KHASHEI, M.; HEJAZI, S. R.; BIJARI, M. A new hybrid artificial neural networks and fuzzy regression model for time series forecasting. **Fuzzy Sets and Systems**, v. 159, n. 7, p. 769–786, 2008.

KIA, A. N.; FATHIAN, M.; GHOLAMIAN, M. R. Using MLP and RBF neural networks to improve the prediction of exchange rate time series with ARIMA. **International Journal of Information and Electronics Engineering**, v. 2, n. 4, p. 2–5, 2012.

KISI, O.; CIMEN, M. A wavelet-support vector machine conjunction model for monthly streamflow forecasting. **Journal of Hydrology**, v. 399, n. 1-2, p. 132–140, 2011.

KUBRUSLY, C. S. **The Elements of Operator Theory**. Second Edition. New York: Birkhäuser, 2011.

KUPERMAN, S. C.; MORETTI, M. R.; CIFU, S.; CELESTINO, TARCISIO BARRETO GIÁCOMO, R.; KLAUS, Z. Critérios para fixação de valores limites da instrumentação civil de barragens de concreto e de terra. In: Seminário Nacional de Grandes Barragens, XXX, 2003. **Anais...** Salvador: Comitê Brasileiro de Grandes Barragens, 2003. p.1–16.

LEE, C. C.; CHIANG, Y. C.; SHIH, C. Y.; TSAI, C. L. Noisy time series prediction using M-estimator based robust radial basis function neural networks with growing and pruning techniques. **Expert Systems with Applications**, v. 36, p. 4717–4724, 2009. Elsevier Ltd.

LEVAN, N.; KUBRUSLY, C. S. A wavelet “time-shift-detail” decomposition. **Mathematics and Computers in Simulation**, v. 63, n. 2, p. 73–78, 2003.

LIAO, C.-C. Genetic k-means algorithm based RBF network for photovoltaic MPP prediction. **Energy**, v. 35, n. 2, p. 529–536, 2010.

LIMA, P. C. Wavelet uma Introdução. **Matemática Universitária**, v. 33, p.13-44, 2002.

LIN, G.-F.; WU, M.-C. An RBF network with a two-step learning algorithm for developing a reservoir inflow forecasting model. **Journal of Hydrology**, v. 405, n. 3-4, p. 439–450, 2011.

LIU, Z.; LI, W.; SUN, W. A novel method of short-term load forecasting based on multiwavelet transform and multiple neural networks. **Neural Computing and Applications**, v. 22, n. 2, p. 271–277, 2011.

MABROUK, A. B.; ABDALLAH, N. B.; DHIFAOU, Z. Wavelet decomposition and autoregressive model for time series prediction. **Applied Mathematics and Computation**, v. 199, n. 1, p. 334–340, 2008.

MAHESWARAN, R.; KHOSA, R. Wavelet Volterra Coupled Models for forecasting of nonlinear and non-stationary time series. **Neurocomputing**, v. 149, p. 1074–1084, 2015.

MALLAT, S. **A Wavelet Tour of Signal Processing**. 3^o ed. San Diego: Academic Press, 2008.

MALLAT, S. G. A theory for multiresolution signal decomposition: the waveletrepresentation. **IEEE Transaction on Pattern Analysis and Machine Intelligence**, v. 11, n. 7, p. 674–693, 1989.

MATOS, S. F. **Avaliação de instrumentos para auscultação de barragem de concreto. Estudo de caso: deformímetros e tensômetros para concreto na barragem de Itaipu**, 2002. Universidade Federal do Paraná.

MEYER, Y. **Wavelets-algorithms and applications**. Filadelfia, 1993.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2^o ed. São Paulo: Egard Blucher, 2006.

NBR 8681. **Ações e segurança nas estruturas - Procedimento**. 2003.

PAI, P.-F.; LIN, C.-S. A hybrid ARIMA and support vector machines model in stock price forecasting. **Omega**, v. 33, n. 6, p. 497–505, 2005.

PAI, P.-F.; LIN, K.-P. Application of Hybrid Learning Neural Fuzzy Systems in Reliability Prediction. **Quality and Reliability Engineering International**, v. 22, n. 2, p. 199–211, 2006.

PEREIRA, E. N.; SCARPIN, C. T.; TEIXEIRA JR, L. A. Hybrid wavelet model for time series prediction. **Applied Mathematical Sciences**, v. 9, n. 149, p. 7431–

7438, 2015.

PEREIRA, E. N.; SCARPIN, C. T.; TEIXEIRA JÚNIOR, L. A. Time Series Forecasting By Using a Neural Arima Model Based on Wavelet Decomposition. **Independent Journal of Management & Production**, v. 7, n. 1, p. 252–270, 2016.

ROCHA, V. B. DA. **Uma Abordagem De Wavelets Aplicada À Combinação De Previsões: Uma Análise Teórica E Experimental.**, 2008. Universidade Federal do Paraná.

ROJAS, I.; VALENZUELA, O.; ROJAS, F.; GUILLEN, A.; HERRERA, L.J.; POMARES, H.; MARQUEZ, L.; PASADAS, M. Soft-computing techniques and ARMA model for time series prediction. **Neurocomputing**, v. 71, n. 4-6, p. 519–537, 2008.

SCARPIN, C. T. **Uma metodologia para a previsão de demanda de produtos utilizando redes neurais artificiais de funções de bases radiais modificadas e uma proposta de logística de reposição**, 2012. Universidade Federal do Paraná.

SCARPIN, C. T.; STEINER, M. T. A. Proposal for a Strategic Planning for the Replacement of Products in Stores Based on Sales Forecast. **Pesquisa Operacional**, v. 31, p. 351–371, 2011.

SEDTE; SCS. **Superintendência de Engenharia da Diretoria Técnica, Superintendência de Comunicação Social. Usina Hidrelétrica de Itaipu Aspectos Técnicos das Estruturas Cíveis.** Itaipu Binacional, 2008.

SEO, Y.; KIM, S.; KISI, O.; SINGH, V. P. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. **Journal of Hydrology**, v. 520, p. 224–243, 2015.

SILVEIRA, J. F. A. **Instrumentação e Comportamento de Fundações de Barragens de Concreto.** São Paulo: Oficina de Textos, 2003.

SILVEIRA, J. F. A. **Instrumentação e Segurança de Barragens de Terra e Enrocamento.** São Paulo: Oficina de Textos, 2006.

SOLTANI, S. On the use of the wavelet decomposition for time series prediction. **Neurocomputing**, v. 48, n. 1-4, p. 267–277, 2002.

TEIXEIRA JR., L. A.; PESSANHA, J. F. M.; MENEZES, M. F.; CASSIANO, K. M.; SOUZA, R. C. Redes Neurais Artificiais e Decomposição Wavelet Na Previsão da Radiação Solar Direta. Congresso Latino-Iberoamericano de Investigación Operacional Simpósio Brasileiro de Pesquisa Operacional. **Anais...** . p.1401–1412, 2012.

TEIXEIRA JR, L. A. **Combinação ssa-wavelet de métodos preditivos com ajuste numérico minimax, na geração de previsões.** 114 f. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica, Rio de Janeiro, 2013.

TEIXEIRA, L. L. **Projeção de séries temporais por meio de um método híbrido Wavelet_Neural integrado com Bootstrap**, 107 f. Tese (Programa de Pós Graduação em Métodos Numéricos em Engenharia) - Setor de Tecnologia e Ciencias Exatas, Universidade Federal do Paraná, Curitiba, 2015.

TEIXEIRA, L. L.; TEIXEIRA JR, L. A.; SIQUEIRA, P. H. Séries Temporais : Combinação Linear de Previsões Wavelet- Neural. Simpósio de Engenharia de Produção, XXI, 2014, Bauru. **Anais...** . p.1–15.

TSEKOURAS, G. E. A simple and effective algorithm for implementing particle swarm optimization in RBF network's design using input-output fuzzy clustering. **Neurocomputing**, v. 108, p. 36–44, 2013.

TURE, M.; KURT, I. Comparison of four different time series methods to forecast hepatitis A virus infection. **Expert Systems with Applications**, v. 31, n. 1, p. 41–46, 2006.

VALENZUELA, O.; ROJAS, I.; ROJAS, F.; POMARES, H.; HERRERA, L.J.; GUILLEN, A.; MARQUEZ, L.; PASADAS, M. Hybridization of intelligent techniques and ARIMA models for time series prediction. **Fuzzy Sets and Systems**, v. 159, n. 7, p. 821–845, 2008.

VOORT, M. V. D.; DOUGHERTY, M; WATSON, S. Combining kohonen maps with arima time series models to forecast traffic flow. **Transportation Research Part C-Emerging Technologies** v. 4,n. 5, p. 307-318, 1996.

VERÓL, A. P. **Simulação da Propagação de onda decorrente de ruptura de barragem, considerando a planície de inundação associada a partir da utilização de um modelo pseudo-bidimensional**. 2010. 234 f. Dissertação (Programa de Engenharia Civil), Universidade Federal do Rio de Janeiro/COPPE, Rio de Janeiro, 2010.

VILLWOCK, R. **Técnicas de agrupamento e de hierarquização no contexto de KDD – aplicação a dados temporais de instrumentação geotécnica-estrutural da Usina Hidrelétrica de Itaipu**. 2009. 125 f. Tese (Programa de Pós-Graduação em Métodos Numéricos em Engenharia) - Setor de Tecnologia e Ciencias Exatas, Universidade Federal do Paraná, Curitiba, 2009.

WEDDING, D. K.; CIOS, J. K. Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model. **Neurocomputing**. v.10, n 2, p. 149-168, 1996.







WU, X.-J.; JIANG, G.-C.; WANG, X.-J.; FANG, N.; ZHAO, L.; MA, Y.-M.; LUO, S.-J. Prediction of reservoir sensitivity using RBF neural network with trainable radial basis function. **Neural Computing and Applications**, v. 22, n. 5, p. 947–953, 2012.







ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v. 50, p. 159–175, 2003.







ZHENG, F.; ZHONG, S. Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing. **Word Academy of Science, Engineering and Technology**, v. 5, n. 3, p. 1125–1129, 2011.

ZHU, L.; WANG, Y.; FAN, Q. MODWT-ARMA model for time series prediction. **Applied Mathematical Modelling**, v. 38, n. 5-6, p. 1859–1865, 2014.

APÊNDICE 1 - WAVELETS ADOTADAS NO ESTUDO







ANEXO 1 - INSTRUMENTOS INSTALADOS NA USINA HIDRELÉTRICA DE ITAIPU

ESTRUTURA		Tipos de Instrumentos																	Total			
		Fundação					Concreto							Geod.								
BARRAGEM DE TERRA DIREITA	Piezômetro																					
	Extensômetro Múltiplo																					
	Medidor de Juntas Triortogonal																					
	Medidor de Vazão																					
	Medidor de Assentamento																					
	Total - Fundação																					
	Drenos da Fundação																					
	Medidor de Deformação																					
	Medidor de Juntas																					
	Medidor de Tensão																					
BARRAGEM LATERAL DIREITA	Base Triangular de Pinos																					
	Base de Coordinômetros																					
	Par de Pinos																					
	Termômetro																					
	Total - Concreto																					
	Drenos do Concreto																					
	Alvos Geodésicos (Prisma)																					
	Marco Geodésico																					
	Total de Instrumentos																					
	Total de Drenos																					
BARRAGEM DE TERRA ESQUERDA																						
TOTAL	658	132	22	39	9	860	4290	330	69	77	641	69	50	126	1362	949	20	141	2383	5239		

FONTE: SEDT; SCS (2008)